

**SVEUČILIŠTE U ZAGREBU**  
**FAKULTET PROMETNIH ZNANOSTI**

**Matej Pavić**

**PRIMJENA ČETVEROSTUPANJSKOG MODELA PRIJEVOZNE  
POTRAŽNJE U PLANIRANJU ODRŽIVOG PROMETA GRADA  
SPLITA**

**DIPLOMSKI RAD**

**Zagreb, 2019.**

Zagreb, 12. travnja 2019.

Zavod: **Zavod za cestovni promet**  
Predmet: **Modeliranje i planiranje u cestovnom prometu**

## **DIPLOMSKI ZADATAK br. 5357**

Pristupnik: **Matej Pavić (0055462793)**  
Studij: **Promet**  
Smjer: **Cestovni promet**

Zadatak: **Primjena četverostupanjskog modela prijevozne potražnje u planiranju održivog prometa grada Splita**

### **Opis zadatka:**

Istraživanje treba obuhvatiti analizu četverostupanjskog modela prijevozne potražnje u teorijskom smislu te njegovu primjenu na konkretnom primjeru grada Splita u aplikativnom smislu.

Nakon pregleda teorijskih postavki i opisa metodologije, potrebno je temeljem prikupljenih ulaznih podataka, provedene analize postojećeg stanja odnosno prometne potražnje grada Splita, predložiti prometni model za planiranje prometnih zahvata i mjera na području grada utemeljen na metodologiji četverostupanjskog modela prijevozne potražnje, čija bi implementacijom na području grada Splita doprinijela modeliranju optimalnih prometnih tokova na gradskoj mreži s ciljem planiranja održivog prometa. Zaključno, autor treba dati svoj osvrt na provedeno istraživanje te predložiti smjernice za provedbu predloženog prometnog modela u gradu Splitu. U postupku izrade prometnog modela grada Splita predlaže se primjena programskog alata PTV Visum.

Mentor:

Predsjednik povjerenstva za  
diplomski ispit:

---

izv. prof. dr. sc. Danijela Barić

Fakultet prometnih znanosti

**DIPLOMSKI RAD**

**PRIMJENA ČETVEROSTUPANJSKOG MODELA PRIJEVOZNE  
POTRAŽNJE U PLANIRANJU ODRŽIVOG PROMETA GRADA  
SPLITA**

**APPLICATION OF FOUR-STEP TRAVEL DEMAND MODEL FOR  
PLANNING SUSTAINABLE TRANSPORT OF THE CITY OF SPLIT**

Mentor: izv. prof. dr. sc. Danijela Barić

Student: Matej Pavić

JMBAG: 0055462793

Zagreb, rujan 2019.

## SAŽETAK

Istraživanje u diplomskom radu obuhvatilo je analizu četverostupanjskog modela prijevozne potražnje u teorijskom smislu te njegovu primjenu na konkretnom primjeru grada Splita u aplikativnom smislu. Nakon pregleda teorijskih postavki i opisa metodologije, prikazana je analiza postojećeg stanja odnosno prometne potražnje grada Splita temeljem koje je izrađen model prometne potražnje grada u programskom alatu PTV Visum. Modelirano je i povećano opterećenje mreže uslijed turističke sezone te jedno prometno rješenje. Zaključno, predložene su smjernice za implementaciju prometnog modela i potpuni dovršetak projekta izgradnje reprezentativnog modela cestovne gradske mreže u gradu Splitu.

KLJUČNE RIJEČI: planiranje, modeliranje, prometna potražnja, održivi promet, četverostupanjski model, PTV Visum, grad Split

---

## SUMMARY

The research in the diploma thesis included the analysis of the four-step model of transport in theoretical terms and is based on the concrete example of the city of Split in the applied sense. After reviewing the theoretical data and the described methodologies, an analysis of the current situation of travel demand of the city of Split is presented which is made according to the model of the city travel demand in the PTV Visum software tool. One traffic solution and one increased network load followed by tourist seasons are modelled. In conclusion, guidelines for the implementation of the traffic model and the complete completion of the project of building a representative model of the city road network in the city of Split are proposed.

KEY WORDS: planning, modelling, travel demand, sustainable transport, four-step model, PTV Visum, City of Split

## Sadržaj

1.	UVOD .....	1
2.	POLAZNE OSNOVE .....	3
2.1.	Prometno modeliranje.....	3
2.2.	Modeli i njihova uloga.....	3
2.2.1.	Značajke prometne potražnje .....	4
2.2.2.	Značajke prometne ponude .....	5
2.2.3.	Ekvilibracija ponude i potražnje .....	5
2.3.	Odabir pristupa modeliranju .....	7
2.4.	Opći problemi modeliranja.....	13
2.4.1.	Uloge teorije i podataka .....	13
2.4.2.	Specifikacija modela .....	14
2.4.3.	Modeliranje, prognoziranje i prosudba .....	16
2.5.	Agregirano i dezagregirano modeliranje.....	16
3.	METODOLOGIJA.....	18
3.1.	Klasični četverostupanjski model prijevozne potražnje .....	18
3.2.	Računalni alati za izradu modela.....	19
3.2.1.	PTV Visum.....	19
3.2.2.	PTV Vissim .....	22
3.3.	Prikupljanje podataka .....	23
3.3.1.	Sekundarni podaci .....	24
3.3.2.	Primarni podaci.....	24
3.3.2.	Određivanje veličine uzorka .....	28
3.4.	Izrada mreže i zona.....	30
3.4.1.	Izrada zona .....	30
3.4.2.	Izrada cestovne mreže .....	32
3.5.	Generiranje putovanja.....	34
3.5.1.	Značajke putovanja .....	34
3.5.2.	Podmodel generiranja putovanja u programskom alatu PTV Visum.....	37
3.6.	Distribucija putovanja.....	38
3.6.1.	Generalizirani trošak putovanja .....	38
3.6.2.	Gravitacijski model .....	39
3.6.3.	Podmodel distribucije putovanja u programskom alatu PTV Visum.....	40

3.7.	Modalna razdioba putovanja .....	42
3.7.1.	Multinomijalni logit modeli .....	43
3.7.2.	Podmodel modalne razdiobe putovanja u programskom alatu PTV Visum .....	44
3.8.	Dodjeljivanje putovanja na mrežu .....	46
3.8.1.	Ekvilibrirana metoda .....	47
3.8.2.	Podmodel dodjeljivanja putovanja u PTV Visum-u .....	49
4.	IZRADA MODELA GRADA SPLITA .....	51
4.1.	Opći podaci i prometne značajke grada Splita .....	51
4.1.1.	Geografski i prometni položaj .....	51
4.1.2.	Turizam .....	52
4.1.3.	Demografski pokazatelji .....	53
4.1.4.	Gospodarstvo .....	53
4.2.	Izrada mreže .....	55
4.2.1.	Izrada elemenata mreže .....	55
4.2.2.	Izrada zona .....	57
4.3.	Generiranje putovanja grada Splita .....	59
4.3.1.	Ulazni podaci .....	59
4.3.2.	Atributi zone .....	59
4.4.	Distribucija putovanja grada Splita .....	66
4.4.1.	Izrada SKIM matrice .....	66
4.4.2.	Izrada matrice distribucije putovanja .....	66
4.5.	Dodjeljivanje putovanja na mrežu grada Splita .....	67
4.5.1.	Dodjeljivanje putovanja za ljetno razdoblje .....	70
4.5.2.	Modeliranje idejnog rješenja .....	72
5.	SMJERNICE ZA DOVRŠETAK MODELA .....	76
5.1.	Izrada reprezentativne mreže .....	76
5.1.1.	Korekcije linkova i nodova .....	76
5.1.2.	Detaljnije zone .....	78
5.2.	Modalna raspodjela putovanja .....	78
5.3.	Primarni podaci .....	79
5.3.1.	Određivanje uzorka .....	79
5.3.2.	Izrada anketnog obrasca .....	79
6.	ZAKLJUČNA RAZMATRANJA .....	81
	LITERATURA .....	83

Popis slika .....	85
Popis tablica .....	86
Popis priloga .....	86

# 1. UVOD

Promet se, kao i svijet, mijenja ubrzano. Ceste su sve zagušenije, pogotovo gradske. Razlozi za to su jednostavni, rješenja nažalost nisu. Gradovi rastu uslijed konstantne urbanizacije, a njihov rast ne može pratiti postojeća infrastruktura. Kupovina vozila postaje sve dostupnija u većini svjetskih zemalja što znatno povećava stupanj motorizacije te za posljedicu ima prometna zagušenja, onečišćenja zraka, onečišćenja bukom i mnoge druge negativne pojave.

Osim spomenutih prometnih problema, novije vrijeme donosi i tehničke alate za rješavanje istih. Danas je moguće modelirati prometne tokove unatoč njihovoj dinamičnosti korištenjem raznih simulacijskih alata.

Svrha ovog diplomskog rada je ukazivanje važnosti i mogućnosti održivog planiranja prometa izradom modela prometnih tokova.

Cilj ovog rada je prikaz metodologije izrade četverostupanjskog modela prijevozne potražnje te njena primjena na konkretnom primjeru grada Splita uz korištenje programskog alata PTV Visum. Izradom modela može se ispitivati predložena rješenja prije poduzimanja zahvata i mjera u stvarnom prostoru, čime se smanjuje vjerojatnost pogreške.

Diplomski rad sadrži šest poglavlja:

1. Uvod
2. Polazne osnove
3. Metodologija
4. Izrada modela grada Splita
5. Smjernice za dovršetak modela
6. Zaključna razmatranja

Polazi se od uvođenja u problematiku potrebe za prometnim modeliranjem, upoznavanjem sa tehničkim alatima koji će se koristiti te definiranjem svrhe i ciljeva istraživanja. U sklopu prvog poglavlja predložena je i struktura rada.

U drugom poglavlju detaljnije je predstavljeno modeliranje kao odgovor modernim prometnim problemima. Naglašen je cilj ekvilibracije ponude i potražnje te je definirana uloga podataka.



U trećem poglavlju opisana je izrada četverostupanjskog modela prometne potražnje prema stupnjevima ili podmodelima. Prethodno je u istom poglavlju opisan programski alat PTV VISUM te metode prikupljanja podataka.

U četvrtom poglavlju izrađen je prometni model za područje grada Splita. Svi podaci na kojima se temelji simulacija su sekundarni. Podmodel modalne razdiobe putovanja nije izrađen, već je opisan u slijedećem poglavlju jer zahtjeva prikupljanje velike količine primarnih podataka, a takav proces iznimno je kompleksan te iziskuje značajnije resurse stoga nije moguće u potpunosti izraditi ga u okviru diplomskoga rada.

Dodatni koraci koji su neophodni pri mogućoj izradi reprezentativnog modela prikazani su u petom poglavlju. Takav model je relevantan donosiocima odluka jer predstavlja temelj za kreiranje prometnih rješenja. U ovom poglavlju predlažu se smjernice kojima se ispravlja i upotpunjuje izrađeni model.

Šesto poglavlje iznosi zaključna razmatranja o cjelokupnom radu te daje ocjenu izrađenih modela. Opisani su gradski problemi te naglašena važnost primjene simulacijskih alata u planiranju održivog cestovnog prometa grada.

## **2. POLAZNE OSNOVE**

### **2.1. Prometno modeliranje**

Prometno modeliranje je sastavni dio prometnog inženjerstva.

Prometno modeliranje ima veliki značaj za analize postojećeg stanja prometa radi predviđanja budućeg stanja u prometu, s obzirom da je promatranje realnog prometnog sustava izrazito skupo što predstavlja problem većine istraživanja u okviru prometnih studija.

Praktični pristup izradi prometnih studija podrazumijeva rješavanje prometnih problema na način da se najprije definiraju prometni modeli, a zatim predložena rješenja provedu u stvarnim uvjetima.

Modeliranje u prometu primjenjuje se u svim područjima prometnog inženjerstva, od planiranja, projektiranja i poslovanja. Iako je planiranje prometa tradicionalno najzahtjevnija faza u smislu definiranja modela, inteligentne tehnologije i tehnike koje se primjenjuju u području prometa povećale su potražnju za modeliranjem u okviru projektiranja i ostalih aktivnosti u području prometa. Prometno modeliranje je sastavni dio prometnog inženjerstva.

Praktični pristup izradi prometnih studija i rješavanju prometnih problema pristupa se na način da se najprije definiraju prometni modeli, a zatim predložena rješenja provedu u stvarnim uvjetima. [1]

### **2.2. Modeli i njihova uloga**

Model je pojednostavljen prikaz dijela stvarnog svijeta (sustava interesa) koji se fokusira na određene elemente koji se smatraju važnima s određenog stajališta. Modeli su stoga ovisni o problemu i točki gledišta. Takva široka definicija uključuje fizičke i apstraktne modele.

U prvoj su kategoriji primjerice, oni koji se koriste u arhitekturi ili u mehanici fluida koji su u osnovi usmjeren na dizajn. U potonjem se raspon proteže od mentalnih modela koji se koriste u svakodnevnom životu kroz interakciju sa svijetom do formalnih i apstraktnih (tipično analitičkih) prikaza neke teorije o sustavu interesa i načinu na koji on funkcionira. Mentalni modeli igraju važnu ulogu u razumijevanju i tumačenju stvarnog svijeta i analitičkih modela. Poboljšavaju se kroz rasprave, obuku i iznad svega, iskustvo. Međutim, mentalne modele je teško komunicirati i raspravljati.

Matematički modeli, važna klasa apstraktnih modela, pokušavaju replicirati sustav interesa i njegovo ponašanje pomoću matematičke jednadžbe temeljene na relevantnim teorijskim tvrdnjama. Iako predstavljaju pojednostavnjene prikaze, ovi modeli mogu biti vrlo složeni i često zahtijevaju veliku količinu ulaznih podataka. Međutim, oni su od neprocjenjive važnosti u pružanju "zajedničke osnove" za raspravu o politici i ispitivanju neizbježnih kompromisa koji se u praksi zahtijevaju s odgovarajućom razinom objektivnosti. Također, važna prednost matematičkih modela je da tijekom njihove formulacije, kalibriranja i korištenja planer može puno učiti, kroz eksperimentiranje, o ponašanju i unutarnjem funkcioniranju sustava pod kontrolom. Na taj se način obogaćuju mentalni modeli i time omogućuje inteligentnije upravljanje transportnim sustavom.

Model je realan samo s određenog gledišta. Primjerice, može biti razumno koristiti nož i viljušku na stolu kao model položaja automobila prije sudara, ali ne i za prikazivanje njihovih mehaničkih značajki ili kao uzorak odabira rute. Isto vrijedi i za analitičke modele: njihova vrijednost je ograničena na niz problema pod određenim uvjetima. Kao što je objašnjeno, prikladnost modela je ovisna o kontekstu u kojem se koristi. Sposobnost izbora i prilagodbe modela za pojedine kontekste jedan je od najvažnijih elemenata cjelokupnog alata za planiranje. [2]

### 2.2.1. Značajke prometne potražnje

Potražnja za prijevozom nije svrha sama po sebi. Uz moguću iznimku razgledavanja, ljudi putuju kako bi zadovoljili određenu potrebu (posao, slobodno vrijeme, zdravlje) poduzimajući određenu aktivnost kretanja prema željenoj lokaciji. To je jednako važno za kretanje robe. Kako bi se razumjelo zahtjev za prijevozom, mora se razumjeti način na koji su te aktivnosti raspoređene u prostoru.

Dobar prometni sustav proširuje mogućnosti za zadovoljavanje tih potreba, teško zagušeni ili slabo povezani sustav ograničava mogućnosti te ograničava ekonomski i društveni razvoj.

Potražnja za prijevozom odvija se preko prostora. To se čini trivijalnom izjavom, ali prometna potražnja predstavlja distribuciju aktivnosti u prostoru. Postoji nekoliko transportnih problema, koji se mogu tretirati, iako na vrlo agregatnoj razini, bez izričitog razmatranja prostora. Međutim, u velikoj većini slučajeva eksplicitni tretman prostora je neizbježan i vrlo poželjan. Najčešći pristup tretiranju prostora je podjela područja istraživanja na zone i njihovo kodiranje, zajedno s prometnom mrežom, u obliku prikladnom za obradu uz pomoć

računalnih programa. Pri tome, različite metode vrednovanja udaljenosti i dodjeljivanja izvorišta i odredišta (i njihovih atributa) u prostoru bitan su element u analizi prometa.

Prostornost potražnje često dovodi do problema nedostatka koordinacije koji mogu snažno utjecati ravnotežu između ponude i potražnje za prijevozom. S druge strane, koncentracija stanovništva i gospodarske aktivnosti na dobro definiranim koridorima može dovesti do ekonomske opravdanosti visokokvalitetnog sustava masovnog prijevoza koji ne bi bio održiv u područjima s manjom potražnjom.

Konačno, potražnja i ponuda u prometu imaju vrlo jake dinamičke elemente. Dobar dio potražnje je koncentriran na svega nekoliko sati na dan, posebno u urbanim područjima gdje se većina zagušenja događa tijekom određenih vršnih razdoblja. Ovaj vremenski promjenjiv karakter prijevoza čini ga zahtjevnijim, ali i zanimljivijim za analizirati i prognozirati. Možda bi se prometni sustav mogao dobro nositi s prosječnom potražnjom za putovanjima u određenom području, kada bi se raspodijelila potražnja iz vršnih sati. Postoji niz tehnika koje pokušavaju raspršiti potražnju iz vršnih sati: fleksibilno radno vrijeme, izmijenjeno radno vrijeme, povećanje cijena itd. Međutim, vrhunac i varijacije u potražnji izvan vršnih vrijednosti ostaju središnji problem u modeliranju i planiranju prometa. [2]

### **2.2.2. Značajke prometne ponude**

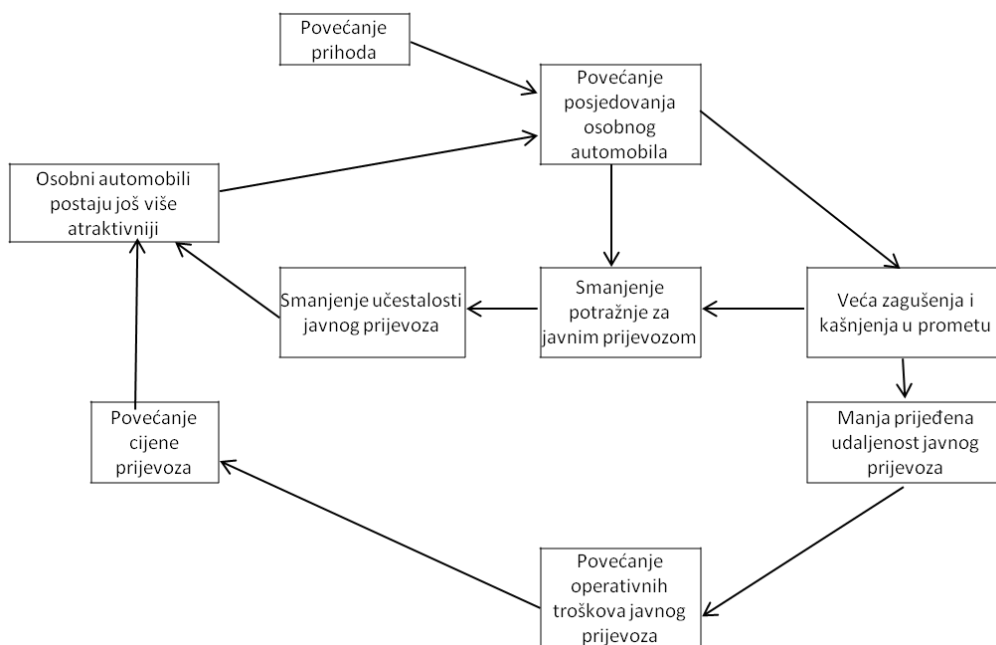
Prva specifična značajka prijevozne ponude je da je to usluga, a ne dobro. Dakle, nije ju moguće skladištiti da bi se koristila u vrijeme veće potražnje. Usluga prijevoza konzumira se kada se i proizvodi, inače se njezina korist gubi. Zbog toga je vrlo važno procijeniti potražnju s što većom točnošću kako bi se uštedjeli resursi tako da se prilagodi prijevozna ponuda.

Mnoge značajke prometnih sustava proizlaze iz njihove prirode kao usluge. U vrlo širokom rasponu pojmovi prometnog sustava zahtijevaju određeni broj stalnih sredstava, infrastrukture i određeni broj vozila. Kombinacija navedenih, zajedno s nizom pravila za njihovo djelovanje, omogućuje kretanje ljudi i dobara.

### **2.2.3. Ekvilibracija ponude i potražnje**

Općenito govoreći, uloga prometnog planiranja je zadovoljiti određenu potražnju za kretanjem osoba i robe s različitim svrhama putovanja, u različito doba dana i godine, pomoću različitih načina rada, s obzirom na transportni sustav s određenim radnim kapacitetom.

Ponekad se vrlo jednostavne uzročno-posljedične veze mogu grafički prikazati kako bi se razumjelo prirode nekih transportnih problema. Tipičan primjer je začarani krug automobila i javnog prijevoza prikazan na Slici 1. [2]



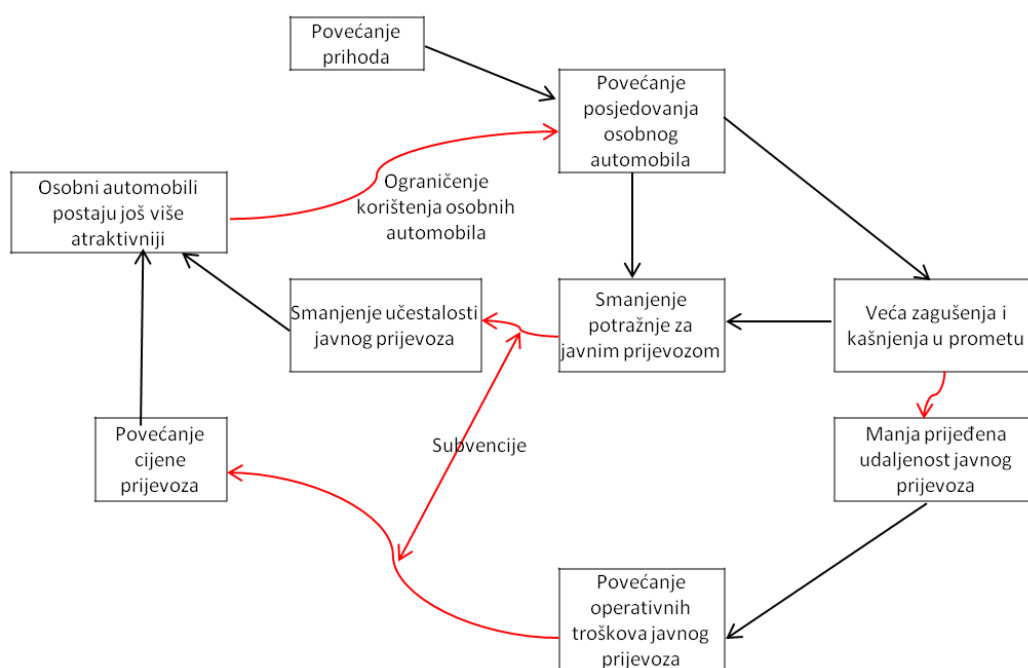
**Slika 1. "Začarani krug" automobila i javnog prijevoza [1]**

Gospodarski rast pruža poticaj povećanju vlasništva nad automobilima. Više vlasnika automobila uzrokuju više ljudi koji žele prijeći s javnog prijevoza na automobil, to opet znači još manje korisnika javnog prijevoza, na koje operateri mogu odgovoriti povećanjem cijene prijevoza, smanjujući učestalost (razina usluge) ili oboje. Ove mjere čine korištenje automobila još atraktivnijim nego prije i potiču još više ljudi na kupnju automobila, čime se ubrzava začarani krug. Nakon nekoliko ciklusa (godina) vozači automobila su suočen s povećanim razinama zagušenja; autobusi kasne, postaju sve skuplji i smanjuje im se učestalost; akumulacija osjetljivih pojedinačnih odluka rezultira konačnim stanjem u kojem su gotovo svi u gorjoj situaciji od prvobitne.

Ovaj jednostavan prikaz također može pomoći da se utvrdi što se može učiniti kako bi se usporio ili preokrenuo začarani krug. Te su ideje sažete na Slici 2. Fizičke mjere kao što su autobusne trake ili sl. te programi prioriteta vozilima javnog gradskog prijevoza posebno su atraktivni jer rezultiraju učinkovitijom alokacijom cestovnog prostora.

Subvencioniranje javnog prijevoza ima snažne zagovornike i klevetnike. Ono može smanjiti potrebu za povećanjem vozarine, barem za kratko, ali ima tendenciju stvaranja velikih deficita zbog zaštite lošeg upravljanja od posljedica vlastite neučinkovitosti.

Sustav za ograničavanje vozila, a posebno naplaćivanje zagušenja, može pomoći u internalizaciji eksternalija i stvaranju izvora prihoda koji se mogu distribuirati u druga područja u prijevozu.



**Slika 2. Prekidanje "Zaćaranog kruga" korištenja osobnih automobila i javnog prijevoza [1]**

Treba biti jasno da nije moguće sve prometne probleme okarakterizirati jedinstvenim, univerzalnim oblikom. Prometni problemi ovise o kontekstu te bi tako trebalo pristupiti i načinima njihova rješavanja. Modeli mogu ponuditi doprinos u smislu identifikacije problema i temeljitijeg odabira rješavanja problema. [2]

## 2.3. Odabir pristupa modeliranju

Prihvatljivost modeliranja ili određenog pristupa modeliranju je vrlo važno prilikom odlučivanja. Prema Ortuzaru [2], modeli koji su na kraju ignorirani od strane donositelja odluka, ne samo da predstavljaju izgubljene resurse i trud, već rezultiraju frustriranim

analitičarima i planerima. Dalje se predlaže da postoji nekoliko obilježja prometnih problema i modela koji se moraju uzeti u obzir pri određivanju analitičkog pristupa:

**Potrebna je preciznost i točnost.** Ovi pojmovi su ponekad zbunjujući. Točnost je stupanj do kojeg rezultat mjerenja ili modela odgovara istinitim ili prihvaćenim vrijednostima. Točnost je problem koji se odnosi na kvalitetu podataka i modela. Razina točnosti koja je potrebna za pojedine primjene uvelike varira. Često se zahtijeva da je potrebna točnost samo da bi se napravila razlika između dobre i manje dobre sheme. U nekim slučajevima najbolja shema može biti prilično očita, stoga je potrebno manje precizno modeliranje.

Preciznost se odnosi na razinu ili jedinice mjerenja koje se koriste za prikupljanje podataka i isporuku izlaznih podataka modela.

Vrijeme putovanja između dvije točke može se mjeriti u dijelovima sekunde, ali pojedinci mogu procijeniti isto mnogo manje precizno u intervalima od pet minuta. Preciznost nije točnost i često nastaju pogreške u razumijevanju. Izvješćivanje o procjenama s velikom preciznošću često se tumači kao povjerenje u točnost, dok modelari u prometu često koriste precizne brojke za izvještavanje o nesigurnim procjenama. Primjerice, postoji razlika između tvrdnje da je jučer između 8:00 i 9:00 ujutro izmjeren promet na linku X te iznosi 2.347 vozila i tvrdnje da će promet na linku X između 8:00 i 9:00 za pet godina iznositi 3148 vozila. Prva izjava može biti precizna i točna, a druga je jednako precizna, ali sigurno netočna. Manje je pogrešno izvijestiti da se očekuje promet od oko 3.150 vozila. To je najbolje opisano u citatu koji se pripisuje Johnu Maynardu Keynesu: “It is much better to be roughly right than precisely wrong“. [2]

**Kontekst donošenja odluka.** To uključuje usvajanje određene perspektive i izbora uzorka te pokrivenost područja interesa. Izbor perspektive određuje vrstu odluka koje će se uzeti u obzir: strateška pitanja ili sheme, taktičke (upravljačke sustave) sheme ili čak specifični operativni problemi.

Izbor uzorka uključuje određivanje razine analize. Radi li se samo o prijevozu ili uključuje i mjesto aktivnosti? Što se tiče prometnog sustava, je li interes samo za potražnju ili i ponudu na različitim razinama: rad sustava ili dobavljača, trošak dobavljača i tako dalje? Također, koliko opcija treba biti razmotreno da bi zadovoljile različite interesne skupine ili razvile jednu najbolju shemu, pitanje je od ključne važnosti.

Kontekst donošenja odluka će također pomoći u definiranju zahtjeva za model, varijabli koje treba uključiti u model ili se smatraju danim tj. egzogenim.


**Potrebna razina detaljnosti.** Razina rezolucije modeliranog sustava može se opisati kroz četiri glavne dimenzije: geografija, jedinica analize, reakcije u ponašanju i upravljanje vremenom.

Prostor je vrlo važan i njime se može upravljati na agregirani način, kroz nekoliko zona u području krivulje protok/brzina ili na detaljnoj razini pojedinačnih adresa za putovanja s prometnicama opisanim u detalj. Postoji širok raspon opcija u ovom polju i izbor će ovisiti o alatu kojeg se koristi. Ako se radi o detaljnom projektu za promet malog područja, detaljno razvrstane zone sa točnim fizičkim značajkama prometnica bi sačinjavale prikladan mikrosimulacijski model. Strateško planiranje može zahtijevati agregatniji sustav prostornog planiranja. [2]


U praksi se najčešće modeli dijele prema stupnju detaljnosti i području obuhvata:

- Mikroskopski modeli - modeliranje kretanja pojedinačnih vozila unutar nekog manjeg područja (npr. raskrižja) kao na Slici 3.
- Mezoskopski modeli - kombiniraju značajke mikroskopskih i makroskopskih modela (simuliraju ponašanje pojedinačnih vozila, ali opisuju njihovo kretanje i interakcije na temelju makroskopskih odnosa). Primjer je prikazan na Slici 4.
- Makroskopski modeli - koriste se za analizu ukupnog prometnog opterećenja prometnica na većoj prometnoj mreži (npr. grad, država). Simuliraju prometne tokove uzimajući u obzir osnovne parametre prometnoga toka (brzina prometnoga toka, protok vozila i gustoća prometnoga toka) i odnose između njih. (Slika 5.) [1]





Slika 3. Mikroskopski modeli [3]



Slika 4. Mezoskopski model [4]



**Slika 5. Makroskopski model [5]**

Jedinica interesa za modeliranje može biti zona s putovanjima koja proizlaze i završavaju u istoj ili u nekoj drugoj zoni, uzorkovani ili sintetizirani pojedinci, različiti slojevi kućanstva ili osobe kao predstavnici putujuće populacije.

Uključene reakcije u ponašanju mogu varirati od prilično jednostavnih postupaka odabira rute u prometu do promjene vremena putovanja, načina putovanja, odredišta, učestalosti putovanja i sl.

Vrijeme se može tretirati kao diskretna ili kontinuirana varijabla. U prvom slučaju model može pokriti cijeli dan (kao u mnogim nacionalnim modelima), razdoblje vrhunca ili manji vremenski interval. To podrazumijeva da će se sve relevantne reakcije dogoditi u tom razdoblju, iako mogu postojati interakcije s drugim razdobljima. Alternativno, vrijeme se može smatrati kontinuiranom varijablom koja omogućuje više dinamičnosti, upravljanje prometnim i ponašajnim reakcijama poput izbora vremena putovanja. S obzirom da je promatranje vremena kao kontinuirane varijable mnogo zahtjevnije, učestalije se koriste vremenski intervali diskretne varijable. [2]

U nekim slučajevima može biti dostupno vrlo malo podataka, u drugima mogu postojati razlozi za sumnju u informacije ili manjak povjerenja u buduće prognoze ključnih varijabli planiranja nedovoljne stabilnosti sustava. U mnogim slučajevima dostupni podaci bit će ključan čimbenik u odlučivanju pristupu modeliranja.

Treba imati na umu da u praksi svi modeli podrazumijevaju da su neke varijable egzogene. Štoviše, mnoge druge varijable izostavljene su iz okvira modeliranja na temelju relevantnosti, teško ih je predvidjeti ili se očekuje da će se malo promijeniti, a ne utječu bitno na sustav interesa. Izričito razmatranje onoga što je izostavljeno iz modela može pomoći pri odlučivanju o njegovoj prikladnosti za određeni problem.

Dostupni resursi za studiju uključuju novac, podatke, računalni hardver i softver, tehničke vještine itd. Međutim, ovdje valja istaknuti dvije vrste resursa: vrijeme i razina komunikacije s donositeljima odluka i javnošću. Donositelji odluka skloni su uspostavljanju apsurdno kratkih vremenskih rokova za procjenu projekata koji će trebati godine da se obradi kroz odluke između višestrukih izbora, godine za provedbu i još mnogo godina da bi potvrdile kao ispravne ili pogrešne procjene. S druge strane, dobra razina komunikacije s donositeljima odluka i javnosti ublažit će ovaj problem. Manje nerealnih očekivanja o mogućnosti preciznog modeliranja prometnih shema i bolje razumijevanje prednosti i ograničenja modeliranja ublažiti će ekstreme slijepog prihvatanja ili potpunog odbacivanja preporuke studije.

Zahtjevi za obradu podataka su ključni. Ovaj se aspekt nekada tumačio kao “Koliko veliko računalo trebate?”. “Odgovor na to pitanje danas je “ne baš veliko”, budući će dobro mikroračunalo poslužiti u većini slučajeva. Stvarno usko grlo u obradi podataka je ljudska sposobnost prikupljanja, unošenja podataka, pokretanja programa i interpretiranja izlaza. Što je razina detaljnosti veća, to će sve te ljudske zadaće biti teže. Korištenje računalno potpomognutog prikupljanja podataka i grafičkih rješenja za input-output programa donekle smanjuju teret.

Razine obuke i vještine analitičara od velike su važnosti. Troškovi obuke su najčešće prilično visoki, toliko da je ponekad bolje koristiti postojeći model ili softver koji je dobro razumljiv, nego upustiti se u nabavu i učenje uporabe nešto naprednijeg. Ovo izgleda kao recept za gušenje inovacija i napretka, međutim uvijek bi trebalo omogućiti trošenje nešto vremena na izgradnju snaga u novim naprednim tehnikama, ali bez odbacivanja iskustva stečenog s ranijim modelima. [2]

Perspektiva modeliranja i uzorak su neizostavni faktori. Razine analize mogu uključivati šest različitih skupina čimbenika, gdje se čimbenik usredotočuje na jedan ili više modela i njihove specifične algoritme rješavanja. Čimbenici mogu biti: lokacije potražnje, lokacije ponude, čimbenici transportnog sustava, čimbenici nabave i sl.

Najveća i najviše agregirana je strateška razina perspektive. Analiza i izbor na ovoj razini imaju velike sustave i dugoročne utjecaje, a obično uključuju prikupljanje resursa i dizajn mreže. Taktička pitanja imaju užu perspektivu i odnose se na pitanja kao što su iskorištavanje postojećih objekata i infrastrukture. Najuža perspektiva, operativna, bavi se kratkoročnim problemima usluga prijevoza. [2]

## 2.4. Opći problemi modeliranja

U radu „Transport Modelling“ [2], autori navode zanimljiv popis pitanja koja je definirao Wilson (1974.) u svom radu „Urban and Regional Models in Geography and Planning“ na koja bi trebao odgovoriti svaki potencijalni modelar, od širokih pitanja kao što je svrha izgradnje modela, do detaljnih aspekata kao što su tehnike dostupne za izgradnju modela. U nastavku ovog potpoglavlja dani su odgovori na ključna pitanja.

### 2.4.1. Uloge teorije i podataka

Teoretski okvir pružiti će određenu vjerodostojnost modela u svrhu predviđanja budućeg ponašanje. Zanimljivo je razmisliti o utjecaju koji praksa i teorija mogu imati jedno na drugo. Primijećeno je da su modeli ili analitički oblici koji su se koristili u praksi tradicionalno imali utjecaj na pretpostavke korištene u razvoju naknadnih teorijskih okvira te je također dobro poznato da su široko primijenjeni oblici, kao što je gravitacijski logit model, predmet jake post hoc racionalizacije:

“Teoretski napretci su posebno dobrodošli kada učvrste postojeću praksu koja bi mogla biti nedostatak osobito uvjerljivog razloga.“ (Williams i Ortuzar)

Pitanje podataka usko je povezano s pitanjima poput vrsti varijabli koje će se koristiti u modelu i to je, naravno, usko povezano s pitanjima o teoriji. Modeli predviđaju broj ovisnih varijabli s obzirom na druge neovisne varijable. Za testiranje modela obično su potrebni podaci o svakoj varijabli. Od posebnog interesa su varijable politika, to su one za koje se



pretpostavlja da su pod kontrolom osobe koja donosi odluke, njih analitičari mogu varirati kako bi se testirale varijantne politike ili sheme. [2]

Također važno pitanje u ovom kontekstu je agregacija [2]:

- Koliko populacijskih slojeva ili vrsta ljudi treba uključiti kako bi se postigla dobra zastupljenost i razumijevanje problema?
- Koliko je potrebno detaljno izmjeriti određene varijable da bi se replicirala određena pojava?
- Prostor je presudan u prometu. Na kojoj razini detaljnosti treba kodirati izvorišta i odredišta putnika kojima će se modelirati njihova putovanja?

### 2.4.2. Specifikacija modela

Specifikacija modela, u svom najširem smislu, prema [2] razmatra sljedeće teme: struktura modela, funkcionalni oblik, specifikacije varijabli.

#### STRUKTURA MODELA

Treba dati odgovor na pitanje: “Je li moguće replicirati sustav na način da se modelira jednostavnom strukturom koja pretpostavlja, na primjer, da su sve varijante neovisne, ili je potrebno graditi složenije modele koji računaju vjerojatnosti izbora uvjetovane prethodnim odabirima?”

#### FUNKCIONALNI OBLIK

Je li moguće koristiti linearne oblike ili problem zahtijeva postuliranje više složenih nelinearnih funkcija? Potonje mogu točnije predstavljati sustav interesa, ali svakako će biti zahtjevnije u smislu resursa i tehnika za kalibraciju i uporabu modela. Iako teoretska razmatranja mogu odigrati veliku ulogu u rješavanju ovog pitanja, također je moguće ispitati ga na induktivan način pomoću laboratorijskih simulacija.

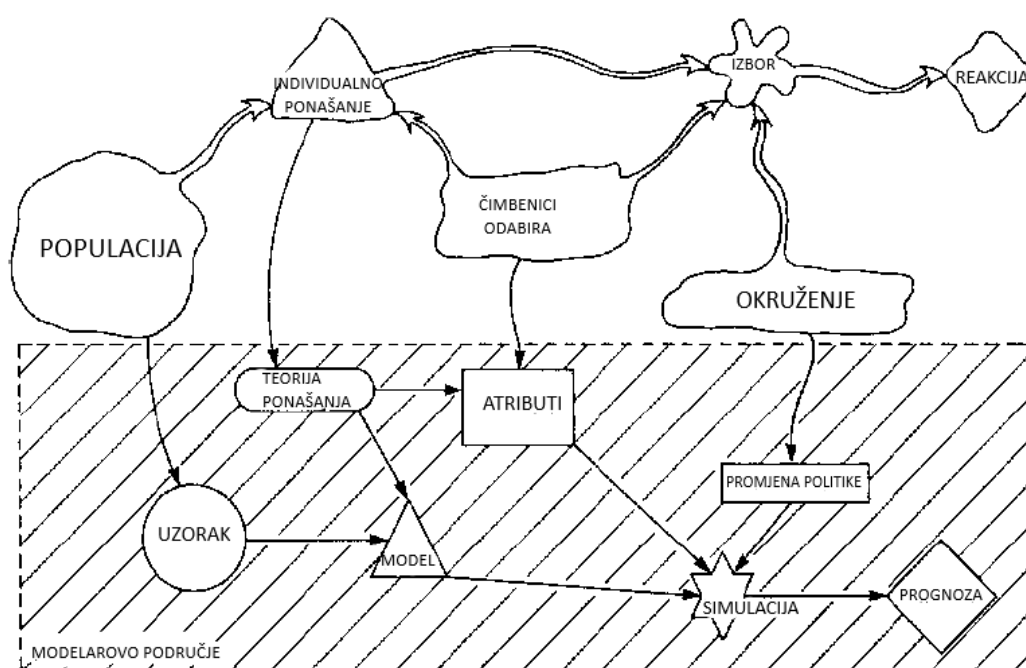
#### SPECIFIKACIJE VARIJABLI

Jedan od prvih zadataka s kojim se modelar suočava je odluka koje će varijable biti predviđene modelom, a koje su eventualno potrebne kao ulazni podaci. Neke od njih uopće neće biti uključene jer modelaru nedostaje kontrola nad njima ili se jednostavno ne uklapaju u teoriju. To podrazumijeva određeni stupanj pogreške i nesigurnosti svojstvene modeliranju, npr. greške u uzorkovanju i, što je još važnije, pogreške zbog neizbježnog pojednostavljenja

stvarnosti koje zahtijeva model kako bi bio praktičan (Slika 6). Stoga je glavna primjena modela u praksi uvjetno prognoziranje: model će proizvesti procjene zavisnih varijabli s obzirom na skup nezavisnih varijabli. [2]

Tipične prognoze uvjetovane su na dva načina [2]:

- u odnosu na vrijednosti dodijeljene varijablama politike u planu, čiji se učinak testira s modelom;
- u odnosu na pretpostavljene vrijednosti drugih varijabli.



**Slika 6. Modeliranje i uzorkovanje (autor prilagodio prema [2])**

Model se obično koristi za testiranje niza različitih planova za niz mogućih pretpostavki budućih vrijednosti varijabli (npr. scenarije niskog i visokog dohotka). To znači da može biti korišten više puta u kontekstu ispitivanja određenog problema. Iz tog razloga može biti presudno da njegove specifikacije omogućuju brze preinake prilikom rada na računalu. To nije lak zadatak u slučaju punog transportnog modela koji uključuje složene procese uravnoteživanja ponude i potražnje.

### 2.4.3. Modeliranje, prognoziranje i prosudba

Postoji razlika između modeliranja i prognoziranja. Modeliranje se fokusira na izgradnju i primjenu odgovarajućih alata koji su osjetljivi na odabrane interese. Uspješan modelar će pružiti korisne i pravovremene savjete u procesu donošenja odluka, čak i ako su podaci i vremenski rokovi ograničeni. U ovom slučaju, važno je da model proizvodi dosljedne rezultate za sve očekivane intervencije, politike i projekte, tako da mogu biti rangirani pravedno, čak i ako korespondencija sa stvarnošću nije savršena. [2]

Prognoziranje je pokušaj predviđanja i kvantificiranja budućih uvjeta. Obično uključuje procjenu buduće potražnje za putovanjima te rezultirajuće multimodalne tokove i troškove tijekom vremena. U slučaju projekata privatnog sektora te su projekcije obično popraćene prognozama prihoda i investitori će uzeti u obzir rizike na temelju tih prognoza. Prognoza se obično temelji na formalnom modelu, ali on sam ne može pružiti cjelovitu sliku, potrebno je uključiti druge analize i pretpostavke. S obzirom na neizvjesnost budućnosti, može se koristiti nekoliko komplementarnih pristupa u prognoziranju. Primjerice, formalni model može biti podržan razmatranjem glavnih ekonomskih pokretača budućih putnih aktivnosti na promatranom području.

S obzirom na prirodu analitičkih modela, nužno je tumačenje njihovih rezultata. Tumačenje zahtijeva dobru prosudbu, a to se stječe samo s iskustvom i temeljitim razumijevanjem teorija o modelima i njihovih ograničenja. Većina modela koji se koriste pretpostavljaju racionalno donošenje odluka putnika. Međutim, postoji sve više čvrstih dokaza, većinom pruženih od bihevioralne ekonomije i psihologije, da ljudi nisu ni potpuno racionalni niti dosljedni u svojim izborima. Ovi dokazi čine primjenu prosudbe prilikom tumačenja izlaznih podataka modela još važnijom. [2]

### 2.5. Agregirano i dezagregirano modeliranje

Razina agregacije odabrana za mjerenje podataka važan je problem u izradi studije planiranja prijevoza. Od središnjeg je interesa agregiranje egzogenih podataka, to jest je informacija o drugim stavkama osim ponašanja putnika, koji se smatra endogenim (model ga pokušava replicirati).

Kada model ima za cilj predstaviti ponašanje više od jednog pojedinca (npr. vlasnici automobila koji žive u određenoj zoni), kao što je slučaj u agregiranim modela, određeni

stupanj grupiranja egzogenih podataka je neizbježan. Naprotiv, kada model u osnovi pokušava prikazati ponašanje pojedinaca, kao što je slučaj u disagregiranih modela, egzogene informacije se mogu dobiti i koristiti zasebno za svakog putnika. Često je poželjnije da se, zbog troškova ili drugih razloga koriste manje detaljni podaci.

Predviđanje buduće potražnje ključni je element većine studija u prometnom planiranju. Biti u mogućnosti predvidjeti vjerojatnu upotrebu novih objekata važno je pred odlučivanje o prednostima ili drugim načinima korištenja takvih objekata. Također je važno imati ideju o osjetljivosti potražnje prema važnim varijablama pod kontrolom analitičara. U većini slučajeva predviđanja i procjene osjetljivosti moraju se prikazati na agregatnoj razini, tj. moraju predstavljati ponašanje cijele interesne populacije. [2]

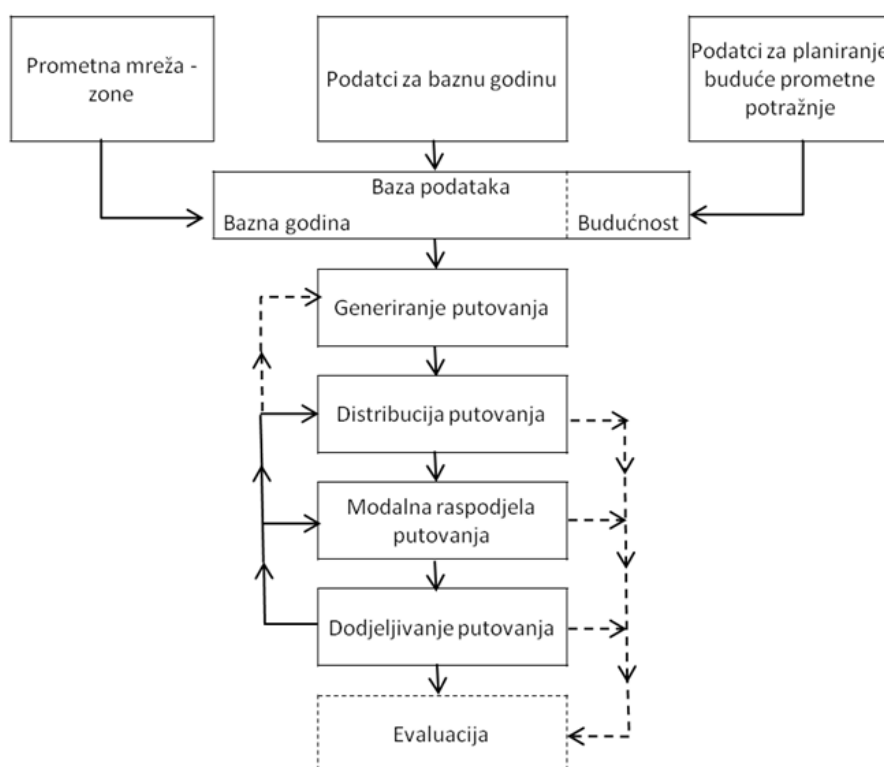


### 3. METODOLOGIJA

#### 3.1. Klasični četverostupanjski model prijevozne potražnje

Godine eksperimentiranja i razvoja rezultirale su općom strukturom koja se naziva klasični model prijevozne potražnje. Ta struktura je, rezultat prakse u šezdesetima, ali je ostala manje-više nepromijenjena unatoč značajnim poboljšanjima u tehnikama modeliranja.

Opći oblik modela prikazan je na Slici 7. Pristup počinje razmatranjem zoniranja i prometne mreže te prikupljanjem i kodiranjem podataka bazne godine za različite tipove populacije u svakoj zoni područja istraživanja kao i razine ekonomske aktivnosti, uključujući zapošljavanje, trgovačke prostore, obrazovne i rekreacijske sadržaje. Ti se podaci zatim koriste za procjenu modela ukupnog broja generiranih i privučenih putovanja po svakoj zoni područja istraživanja (generiranje putovanja). Sljedeći korak je dodjela tih putovanja određenom odredištu, tj. njihova distribucija po prostoru, čime se stvara matrica putovanja. Sljedeće faza obično uključuje modeliranje izbora načina i to rezultira modalnim razdiobom, tj. raspodjelom putovanja u matrici na različite načine. Konačno, zadnja faza u klasičnom modelu zahtijeva dodjeljivanje svakog putovanja na mrežu, prema modu, privatni i javni prijevoz. [2]



Slika 7. Shematski prikaz klasičnog četverostupanjskog modela [1]

Nakon što je model kalibriran i validiran za uvjete bazne godine, mora se primijeniti na jedan ili više horizonata planiranja. Da bi se to postiglo potrebno je razviti scenarije i planove koji opisuju relevantna obilježja transportnog sustava i planskih varijabli pod mogućom budućnošću.

Nakon što su pripremljeni realni scenariji i planovi za testiranje, isti niz modela ponovno se pokreće simulirajući njihovu izvedbu. Uspoređuju se troškovi i koristi izmjerenih različitih shema u različitim scenarijima. Ideja je odabrati najbolji program ulaganja u promet koji zadovoljava potražnju za kretanjem u području istraživanja. [2]

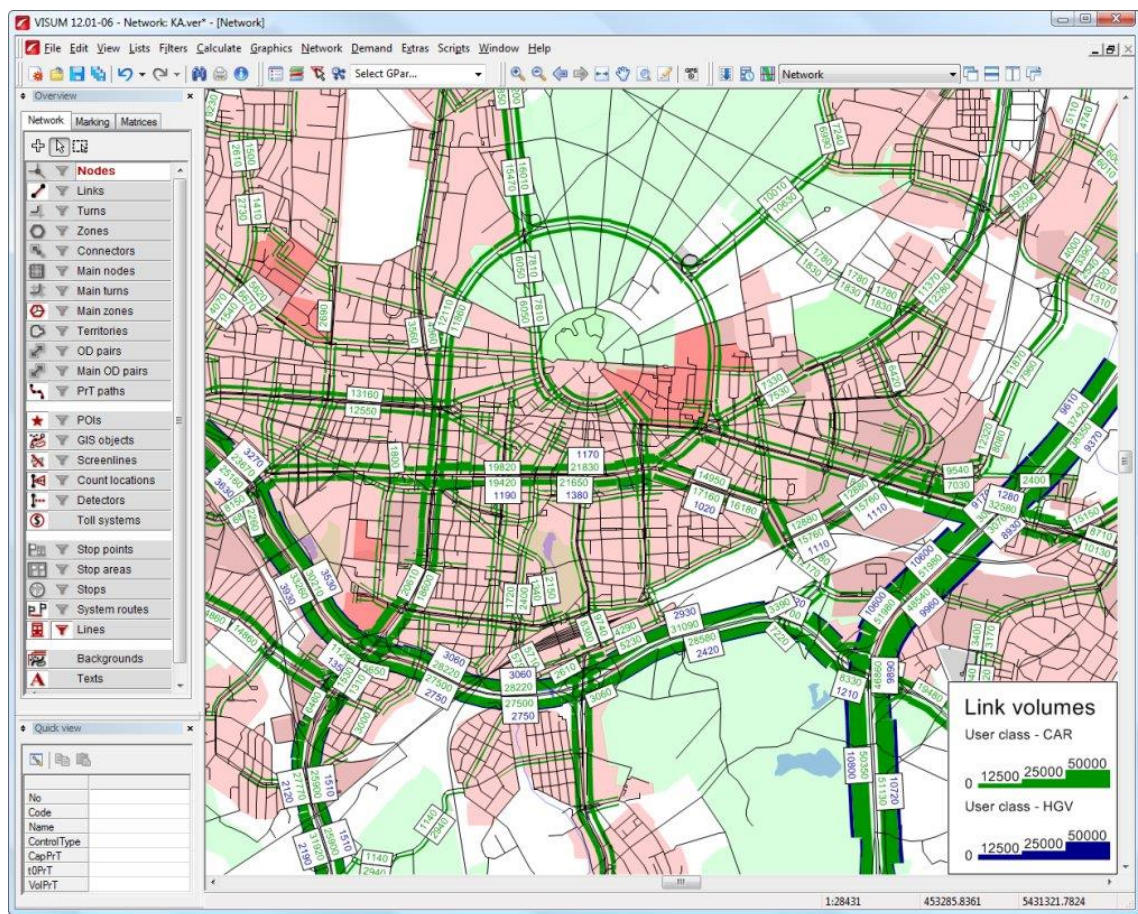
## **3.2. Računalni alati za izradu modela**

### **3.2.1. PTV Visum**

PTV Visum je vodeći svjetski softver za analizu prometa, prognoze i upravljanje podacima temeljenim na GIS-u. Dosljedno modelira sve korisnike cesta i njihove interakcije te je postao priznati standard u području planiranja prometa. Stručnjaci za promet koriste PTV Visum kako bi modelirali transportne mreže i potražnju za putovanjima, analizirali očekivane prometne tokove, planirali usluge javnog prijevoza i razvili napredne prometne strategije i rješenja. Primjer dodjele putovanja u softveru prikazan je na Slici 8.

Ističu se nekoliko mogućnosti pri korištenju ovakvog softvera za izradu transportnog modela:

- Mogućnost učitavanja PrT i PuT mreže iz nekoliko izvora (oblik, DIVA, HAFAS, OpenStreetMap itd.)
- Transparentno računanje različitih modela potražnje (4-stupnjevani algoritam, Visem, Viseva) integriranih u PTV Visum i izvođenje pouzdane prognoze na temelju dobro utemeljenog modeliranja potražnje
- Odabir odgovarajućih postupaka dodjele i smanjenja odstupanja od brojčanih vrijednosti pomoću tehnika matrične korekcije
- Korištenje transportnog modela za kvantificiranje scenarija, razvoj događaja i njihove pripreme za analizu
- Omogućavanje političkim predstavnicima sveobuhvatan i pouzdan pogled u budućnost uz pomoć jasnih mapa i tablica



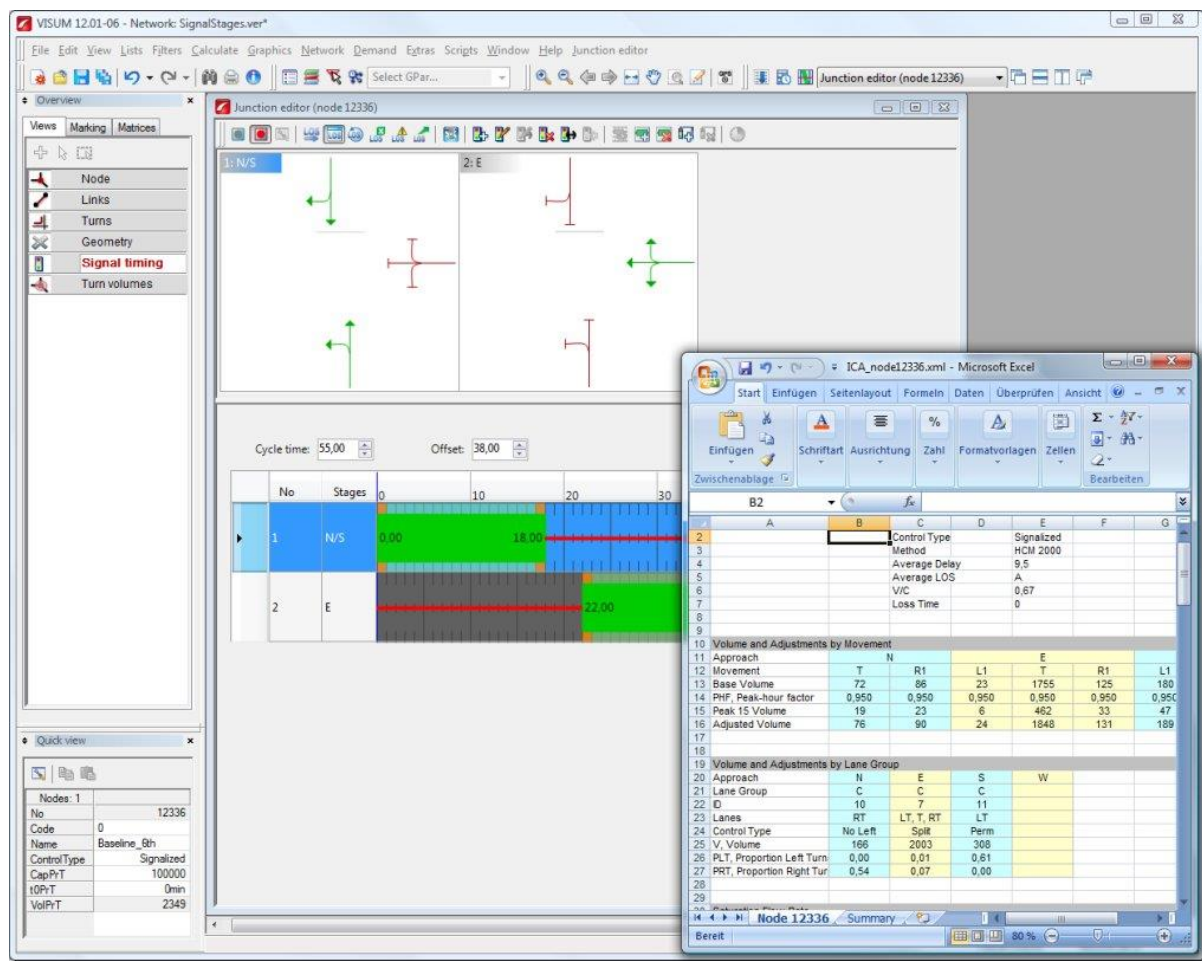
**Slika 8. Rezultat dodjele putovanja na mrežu u Visum-u [5]**

Svaka tvrtka koja nudi usluge javnog prijevoza mora provjeriti isplativost svojih usluga. To uključuje detaljnu analizu rezultata po operatorima, linijama, korisnicima karata i drugim značajkama. PTV Visum nudi širok raspon mogućnosti procjene i pomaže u prepoznavanju potencijalnih ušteda.

Što se tiče izgradnje i razvoja cesta, softver omogućava realno modeliranje na temelju kalibrirane stvarne situacije i referentnog slučaja. Također, može se stvoriti baza podataka za ekonomske analize te izvršiti daljnja istraživanja o utjecaju na okoliš (npr. studije o buci) u okviru planiranja razvoja. Ekonomske analize optimalne varijante prometno-tehnoloških projekata utemeljene na relevantnim metodama nužne su i predstavljaju osnovu za donošenje odluke o investiranju. [6] PTV Visum je svestrani alat koji se također može koristiti za prometne inženjerske aplikacije, uključujući detaljnu analizu raskrižja. Svi podaci su odmah dostupni, za mikroskopske (npr. pojedinačna raskrižja) i makroskopske procjene. Tipične aplikacije se kreću od realističnih modela čvorova uključenih u postupak dodjele putovanja do

automatske optimizacije signalnih planova. Još jedna velika prednost je besprijeekorna integracija sa softverom za simulaciju prometa PTV Vissim. [5]

Na Slici 9. prikazana su vremena signalnih planova iz Junction editora. Faze se prikazuju s obje strane i shematskim prikazom slijeda. Preko gumba se može pokrenuti detaljan izračun i rezultati se spremaju u Excel izvješće.



Slika 9. Prikaz signalnih planova odabranog raskrižja [5]

Planiranje razvoja korištenjem Visum-a omogućava:

- prognozu ponude i potražnje temeljene na modelu. To omogućuje realno modeliranje i analizu utjecaja prometa;
  - stvaranje baze podataka za analize ekonomske održivosti i utjecaja na okoliš,
  - izvesti model mreže, potražnju za transportom i odgovarajuća raskrižja u PTV Vissim.
- [5]

### 3.2.2. PTV Vissim

Bez obzira uspoređuje li se geometrija čvorišta, analizira prioritetne sheme javnog prijevoza ili razmatra učinke određenog signalnog plana, PTV Vissim omogućuje simuliranje točnih uvjeta u prometu. Motorizirani privatni prijevoz, prijevoz robe, željeznički i cestovni javni prijevoz, pješaci i biciklisti, Vodeći svjetski softver za simulaciju mikroskopskog prometa - PTV Vissim, prikazuje sve korisnike cesta i njihove interakcije u jednom modelu. To podrazumijeva: motorizirani privatni prijevoz, prijevoz robe, željeznički i cestovni javni prijevoz, pješake i bicikliste. Ovakvi modeli gibanja pružaju realistično modeliranje svih sudionika u prometu.


Softver nudi fleksibilnost u nekoliko aspekata: koncept linkova i konektora korisnicima omogućuje modeliranje geometrije s bilo kojom razinom složenosti. Atributi za vozača i značajke vozila omogućuju pojedinačno parametriranje. Nadalje, velik broj sučelja osigurava besprijekornu integraciju s drugim sustavima za signalne regulatore, upravljanje prometom ili modele emisija.

PTV Vissim je zaokružen sveobuhvatnim mogućnostima analize, stvarajući moćno sredstvo za procjenu i planiranje urbane i izvan-gradske prometne infrastrukture. Primjerice, softver za simulaciju može se koristiti za izradu detaljnih računskih rezultata ili impresivnih 3D animacija za različite scenarije. To je jako dobar način predstavljanja uvjerljivih i razumljivih planiranih infrastrukturnih mjera donositeljima odluka i javnosti.

Od jednostavnih raskrižja, raskrižja upravljanih prometnim svjetlima do raskrižja s kružnim tokom prometa s prioritetom javnog prijevoza i interakcijom pješaka, uz PTV Vissim moguće je modelirati i proučiti bilo koju geometriju čvora i bilo koju vrstu prioriteta i signalizaciju.

Na Slici 10. prikazan je primjer modela raskrižja u gradu Kopenhagenu, koji je jedan od gradova koji najviše na svijetu potiče biciklistički promet. Stoga nije iznenađenje što je danska prijestolnica sebi postavila cilj postati grad s najviše bicikala na svijetu. Nova infrastruktura, zeleni valovi, parkirališta i povećani kapacitet na često korištenim biciklističkim stazama trebao bi pomoći pri okretanju ove vizije u stvarnost. Mjere se simuliraju i unaprijed ocjenjuju pomoću softvera PTV Vissim. [7]






**Slika 10. Multimodalni model raskrižja u Kopenhagenu [7]**

### 3.3. Prikupljanje podataka

Za izradu modela potrebno je izabrati najbolju metodu prikupljanja podataka. Ne postoji idealna metoda, no najbolja metoda je ona koja omogućuje prikupljanje potrebnih ulaznih podataka o kretanju stanovništva uz najmanje financijske i vremenske troškove. Potrebni ulazni podaci trebaju reprezentativno prikazati sav promet na promatranoj mreži.

Problematika kretanja na određenom području prikazana je na Slici 11.



**Slika 11. Područje prikupljanja podataka za OD istraživanja [1]**

### 3.3.1. Sekundarni podaci

Sekundarni podatci su prikupljeni i zabilježeni ranije, u nekom drugom istraživanju, i za neku drugu svrhu. S gledišta istraživača koji provodi istraživanje i služi se sekundarnim podacima, to su povijesni podaci i za sadašnjeg istraživača ne zahtijevaju kontakt s ispitanicima ili subjektima istraživanja. Unatoč nazivu, ovakvi se podaci prikupljaju prije primarnih da se izbjegne uzaludno trošenje vremena i novca na nešto što je već dostupno.

Bilo da se radi o podacima vezanim za promet, bilo da se radi tek o demografskim podacima, mogu biti od velike koristi za izradu reprezentativnog prometnog modela. Potrebno je provjeriti sve potencijalne izvore sekundarnih podataka da bi se pristupilo sljedećoj fazi prikupljanja primarnih podataka. [1]

### 3.2.2. Primarni podaci

Primarni podaci su izvorna opažanja koja se prikupljaju za potrebe rješavanja konkretnog tržišnog problema različitim kvalitativnim ili kvantitativnim tehnikama istraživanja tržišta, i to u slučajevima kada su raspoloživi sekundarni izvori podataka ograničenoga karaktera, nisu odgovarajući ili su zastarjeli. Za potrebe ovog diplomskog rada predloženo je prikupljanje podataka anketiranjem kućanstava i anketiranjem vozača.

**Anketa** je najčešće korištena tehnika prikupljanja podataka u istraživanju kojom se na temelju anketnog upitnika istražuju i prikupljaju podatci, informacije, stavovi i mišljenja o predmetu istraživanja. Najčešće se primjenjuje u društvenim i humanističkim znanostima, ali ima veliku primjenu i u drugim znanstvenim područjima.

Anketni upitnik je formalni popis pitanja koja se postavljaju ispitaniku. Uglavnom se nastoje koristiti zatvorena pitanja koja imaju određene prednosti:

- ne zahtijevaju veće obrazovanje i pismenost ispitanika
- veliki broj ispitanika daje odgovor na takva pitanja
- ispitanici su pred lakšim zadatkom, jer je lakše zaokružiti odgovor nego ga opisivati svojim riječima
- moguće je postaviti veći broj pitanja
- lakše ih je obrađivati
- veća im je verifikacijska vrijednost

**Anketiranje kućanstva** u svrhu istraživanja putovanja predstavlja najskuplji i najkompleksniji tip ankete. Ovakvo istraživanje omogućuje dobivanje najkorisnijih i najopsežnijih podataka o putovanju stanovništva.

Bitno je prikupiti socio-ekonomske podatke o dohotku, posjedovanju osobnog automobila, veličini kućanstva, njegovoj strukturi i sl. Preporuča se provoditi anketiranje od sredine rujna do kraja studenoga kada su rute putovanja najviše ustaljene tijekom godine (kraj ljetnih godišnjih odmora, početak škole).

Najbolji pristup prikupljanju podataka bio bi prikupljati podatke za svaki dan u tjednu tijekom cijele godine i tako za nekoliko godina. Takva istraživanja zahtijevaju značajna financijska sredstva pa u postupku provođenja ankete, anketar prikuplja detaljne informacije o svim putovanjima prethodnoga dana, uključujući vrijeme početka i kraja putovanja, lokaciju izvora i odredišta putovanja, svrhu putovanja, korištene modove prijevoza, rute putovanja i mjesta eventualnih transfera tijekom putovanja.

S obzirom na oblike komuniciranja, anketiranje kućanstva se može provesti osobno (anketar), slanjem anketnog obrasca poštom ili e-poštom, te provedbom ankete telefonom. Najpouzdaniji podatci dobivaju se provedbom ankete osobno pomoću anketara. Nedostatak anketa poslanih poštom, između ostalog, očituje se u mogućnosti ispunjavanja jednog člana obitelji za sve ostale. Telefonska anketiranja također nisu preporučljiva iz više razloga pa tako npr. u današnje vrijeme mnogi vlasnici telefonskih priključaka nemaju prijavljen broj u imeniku, a sve je veći broj onih koji imaju isključivo mobilne telefone.

Kriteriji za definiranje anketnog obrasca:

- Pitanja trebaju biti jednostavna i direktna.
- Izbjegavati nepotrebna pitanja i osigurati da svako pitanje ima određenu svrhu.
- Broj otvorenih pitanja treba svesti na najmanji mogući broj.
- Pitanja vezana uz informacije o putovanjima trebaju uključiti svrhu putovanja.
- Prikupljati podatke na način da se kasnije u analizi može rekonstruirati svako putovanje.
- Tražiti informacije o svim korištenim modovima prijevoza tijekom putovanja.
- Svi članovi kućanstva trebaju biti uključeni u anketu.



- S obzirom da se ljudi često teško prisjećaju neki prošlih putovanja preporuča se unaprijed poslati dnevnik u koji će za zadani dan unositi podatke o svim svojim putovanjima.
- Preporuka je da se svi prikupljeni podatci razrade na najvišoj razini te pri tome
- koriste suvremeni alati.

Neovisno o obliku komuniciranja tijekom provedbe ankete, preporuča se sastaviti anketu koja će sadržavati dijela, s obzirom na sadržaj podataka i informacija, a to su:

### 1. Podatci o značajkama kućanstva i svakog člana kućanstva

Ovaj prvi dio sadrži pitanja temeljem kojih će se klasificirati članovi kućanstva, a to su pitanja koja se odnose na odnos članova prema tzv. glavi obitelji (npr. supruga, kćerka, sin), spol, dob, posjedovanje vozačke dozvole, stupanj obrazovanja, zanimanje, osobni dohodak.

**SOCIAL CAR**  
**ANKETA KUĆANSTVA - OPĆI PODACI**

BROJ KUĆANSTVA:

PREZIME:  ADRESA:

DATUM:  KONTAKT TELEFON:

01

1) Koliko članova ima vaše kućanstvo? ☐

2) Koliko je članova starijih od 14 godina? ☐

3) Koliko je članova kućanstva jučer boravilo u kućanstvu? ☐

4) Š koliko osobnih vozila raspoložuje vaše kućanstvo? ☐

5) Š koliko motocikala raspoložuje vaše kućanstvo? ☐

6) Š koliko bicikala raspoložuje vaše kućanstvo? ☐

7) Kolika je udaljenost od vašeg kućanstva do najbliže stanice javnog prijevoza? ☐

1 1-5 min. pješićevlje (do 200 m)  
2 6-10 min. pješićevlje (200-500 m)  
3 11-15 min. pješićevlje (500-1000 m)  
4 više od 16 min. pješićevlje (više od 1000 m)

8) Koliko je članova vašeg kućanstva zaposleno? ☐

9) Koliko članova vašeg kućanstva prima mirovinu ili socijalnu pomoć? ☐

10) Kolika su ukupna mjesečna primanja svih članova vašeg kućanstva zajedno? ☐

Mjesečna primanja (din)  
1 2.000 - 5.000  
2 5.000 - 8.000  
3 8.000 - 10.000  
4 11.000 - 14.000  
5 14.000 - 17.000  
6 17.000 - 20.000  
7 preko 20.000

11) Ukupan broj putovanja u danu svih članova kućanstva.

BROJ ANKETARA:  POTPIS ANKETARA:

Slika 12. Anketni obrazac za projekt Social Car, prva strana [1]

## 2. Podatci o putovanjima

Cilj drugog dijela ankete jest utvrditi i opisati sva putovanja svih članova kućanstva koji su utvrđeni u prvom dijelu ankete. Putovanje je sada definirano kao svako kretanje izvan objekta stanovanja te ima određenu svrhu. Svako putovanje treba razdvojiti po etapama, a svaku etapu čini promjena moda putovanja (uključujući i nemotorizirani promet, odnosno pješaćenje). Za svaku etapu putovanja potrebno je prikupiti podatke o svrsi putovanja, vremenu početka i kraja putovanja, troškovima prijevoza, i sl. U idealnom slučaju, na temelju analize trebalo bi biti moguće logički povezati etape putovanja i omogućiti rekonstrukcije kretanja te generirati produkciju i atrakcija kućanstva. Prikupljanje podataka o obilježjima svih jedinica statističkog skupa često nije moguće (preskupo, zahtijeva previše vremena ili nije moguće jer je statistički skup prevelik ili beskonačan), stoga se vrši reprezentativno promatranje kojim se obuhvaća samo dio jedinica statističkog skupa. [1]

Primjer obrasca ankete kućanstva prikaza je na Slici 12. i Slici 13.

SOCIAL CAR ANKETA KUĆANSTVA – PODACI O PUTOVANJIMA									
BROJ KUĆANSTVA		BROJ OSOBE		LIST		OD		STATUS	
[ ] [ ]		[ ] [ ]		[ ] [ ]		[ ] [ ]		[ ] [ ]	
Putovanje broj	IZVOR PUTOVANJA			ODREDIŠTE PUTOVANJA			Vrsta prijevoza (uključiti svi)	Kojim prijevozom sredstvom ste najviše putovali?	Da li ste platili parking? - da, ne
	Adresa	Aktivnost	Vrijeme	Adresa	Aktivnost	Vrijeme			
[ ] [ ]	Ulica: _____ Kućni broj: _____ Mjesto: _____	[ ]	sat min sek	Ulica: _____ Kućni broj: _____ Mjesto: _____	[ ]	sat min sek	[ ] [ ] [ ]	[ ]	[ ]
[ ] [ ]	Ulica: _____ Kućni broj: _____ Mjesto: _____	[ ]	sat min sek	Ulica: _____ Kućni broj: _____ Mjesto: _____	[ ]	sat min sek	[ ] [ ] [ ]	[ ]	[ ]
[ ] [ ]	Ulica: _____ Kućni broj: _____ Mjesto: _____	[ ]	sat min sek	Ulica: _____ Kućni broj: _____ Mjesto: _____	[ ]	sat min sek	[ ] [ ] [ ]	[ ]	[ ]
[ ] [ ]	Ulica: _____ Kućni broj: _____ Mjesto: _____	[ ]	sat min sek	Ulica: _____ Kućni broj: _____ Mjesto: _____	[ ]	sat min sek	[ ] [ ] [ ]	[ ]	[ ]
[ ] [ ]	Ulica: _____ Kućni broj: _____ Mjesto: _____	[ ]	sat min sek	Ulica: _____ Kućni broj: _____ Mjesto: _____	[ ]	sat min sek	[ ] [ ] [ ]	[ ]	[ ]
[ ] [ ]	Ulica: _____ Kućni broj: _____ Mjesto: _____	[ ]	sat min sek	Ulica: _____ Kućni broj: _____ Mjesto: _____	[ ]	sat min sek	[ ] [ ] [ ]	[ ]	[ ]
[ ] [ ]	Ulica: _____ Kućni broj: _____ Mjesto: _____	[ ]	sat min sek	Ulica: _____ Kućni broj: _____ Mjesto: _____	[ ]	sat min sek	[ ] [ ] [ ]	[ ]	[ ]

BROJ ANKETARA [ ] [ ]  
 POTPIS ANKETARA \_\_\_\_\_

Aktivnosti: 1 - kućanstvo 6 - obrazovanje  
 2 - rad 7 - odmor/ugostitelj (ski) objekti  
 3 - poslovanje 8 - kulturni događaji, kino, koncert  
 4 - kupovina 9 - ostalo  
 5 - rekreacija/podizbudo vrijeme

Vrsta prijevoza: 1 - osobni auto (vaga) 5 - motokli  
 2 - osobni auto (putni) 6 - tramvaj  
 3 - taksu 7 - autobus  
 4 - bicikl 8 - bicikl  
 9 - pješaćenje

Slika 13. Anketni obrazac za projekt Social Car, druga strana [1]

**Anketiranje vozača** pruža korisne informacije o putovanjima koja nisu zabilježena u anketama kućanstvu (npr. vanjsko-vanjska putovanja u kordonskim anketama). Često predstavlja bolji način za procjenu matrica putovanje nego anketa kućanstva jer je moguće dobiti veći uzorak. Stoga su ovako prikupljeni podaci također korisni kod provjere podataka

dobivenih anketom kućanstva. Anketiranje vozača podrazumijeva uzorak kojeg čine vozači i putnici u vozilu (npr. osobni automobil, javni prijevoz, teretna vozila).

Ovakvi intervjui su kratki, paleta pitanja je ograničena, a uključuje podatke o izvoristu i odredištu putovanja i svrsi putovanja. Poželjno bi bilo dobiti i podatke kao što su dob, spol i prihodi, ali rijetko su uključeni u anketu zbog vremenskog ograničenja. Međutim, dobro obučeni anketari mogu lako dodati barem dio tih podataka temeljem jednostavnog promatranja vozila i putnika (poteškoće su očekivane u slučaju javnog prijevoza). Provedba anketiranja vozača zahtijeva dobru organizaciju i planiranje kako bi se izbjegle nepotrebne odgode, osigurala sigurnost i u konačnici dobili kvalitetni rezultati. Važni elementi koji će pridonijeti uspješnosti ovakvih istraživanja uključuju identifikaciju pogodnih mjesta za provedbu ankete vozača te suradnja i koordinacija s policijom. [1]

### 3.2.2. Određivanje veličine uzorka

Prikupljanje podataka o obilježjima svih jedinica statističkog skupa često nije moguće (preskupo, zahtijeva previše vremena ili nije moguće jer je statistički skup prevelik ili beskonačan), stoga se vrši reprezentativno promatranje kojim se obuhvaća samo dio jedinica statističkog skupa.

Populacija ili osnovni skup je pojava koja se želi upoznati ili istražiti reprezentativnim promatranjem. Uzorak je dio populacije koji se ispituje (podskup statističkog skupa odnosno podskup populacije). Zaključno, ako se populacija uspoređuje na temelju uzorka, osnovni je preduvjet pouzdanosti zaključaka da su uzorci reprezentativni za populacije iz kojih potječu. Uzorak je reprezentativan ako po svojim osnovnim značajkama nalikuje na osnovni skup odnosno ako predstavlja umanjenu sliku osnovnog skupa. Uzorkom se dolazi do procjene značajki osnovnog skupa, a statističkom metodom određuje se pouzdanost i preciznost te procjene .

**Metoda uzoraka ili reprezentativna metoda** je dio statistike kojoj je glavni zadatak da na temelju konačnog niza podataka otkriva statističke zakonitosti i pripadne parametre promatranih statističkih fenomena. Cilj je donijeti što kvalitetniji zaključak o cijeloj populaciji na temelju podataka uzorka. Zaključci doneseni na temelju uzorka nemaju apsolutnu sigurnost, već se govori o određenoj pouzdanosti izvedenog zaključka. Stoga svaki zaključak sadrži grešku, osim ako uzorak nije jednak čitavoj populaciji. Prema tome, zaključci se mogu

donijeti s određenom razinom pouzdanosti (vjerojatnosti da je zaključak o osobitosti cijele populacije točan).

Prednosti metode uzorka:

- brzina prikupljanja podataka, njihove obrade i dobivanja rezultata
- niži troškovi
- veća pouzdanost rezultata, budući da istraživanje provode statističari i educirani anketari
- mogućnost optimizacije veličine uzorka uz odgovarajući rizik

Ukoliko postoji značajna varijabilnost elemenata statističkog skupa, koristi se **stratificirani uzorak**.

Prvo se osnovni skup podijeli na homogene skupine elemenata koji se nazivaju stratumi. Iz svakog stratuma se slučajnim izborom bira određeni broj jedinica u uzorak, proporcionalno veličini stratuma. Smanjuje se greška uzorkovanja i povećava reprezentativnost uzorka. Nakon provođenja stratifikacije, potrebno je osigurati da je svaka grupa odgovarajuće prezentirana u uzorku.

**Kvotni uzorak** je najvažniji u skupini uzoraka koji se zasnivaju na teoriji slučajnosti. Izbor jedinica određuju istraživači (anketari), ali u sklopu dodijeljene kvote. Takvim postupkom osigurana je zastupljenost različitih podskupina osnovnog skupa u uzorku prema njihovim važnim značajkama upravo na način kako to istraživač odredi. [1]

Veličina anketnog uzorka potrebnog za provođenje ankete o kvaliteti prometne usluge (npr. usluge u javnom gradskom prijevozu) može se odrediti i pomoću kalkulatora potrebne veličine uzorka, koji su dostupni online, a jedan od njih je dostupan na: <http://www.raosoft.com/samplesize.html> i prikazan na Slici 14.

**Sample size calculator**

What margin of error can you accept?  %  
5% is a common choice

What confidence level do you need?  %  
Typical choices are 90%, 95%, or 99%

What is the population size?   
If you don't know, use 20000

What is the response distribution?  %  
Leave this at 50%

Your recommended sample size is **377**

Online surveys with **Vovici** have completion rates of 66%!

**Alternate scenarios**

With a sample size of	100	200	300	With a confidence level of	90	95	99
Your margin of error would be	9.78%	6.89%	5.62%	Your sample size would need to be	267	377	643

Save effort, save time. **Conduct your survey online with Vovici.**

**More information**

If 50% of all the people in a population of 20000 people drink coffee in the morning, and if you were repeat the survey of 377 people ("Did you drink coffee this morning?") many times, then 95% of the time, your survey would find that between 45% and 55% of the people in your sample answered "Yes".

**Slika 14. Raosoft, besplatni online kalkulator veličine uzorka [8]**

Obrazac za veličinu uzorka  $n$  (poznata veličina populacije):

$$n = \frac{N * x}{(N-1) * E^2 + x} \quad (1)$$

$$x = Z_{\left(\frac{c}{100}\right)}^2 * r * (100 - r) \quad (2)$$

Ulazne veličine korisnik zadaje prilikom korištenja navedenog kalkulatora, a to su:

- Prihvatljiva pogreška  $E$  (margin of accepted error)
- Razina pouzdanosti  $c$  (confidence level)
- Očekivana distribucija odgovora  $r$  (response distribution)
- Veličina populacije  $N$  (population size)

### 3.4. Izrada mreže i zona

#### 3.4.1. Izrada zona

Sustav zoniranja koristi se za agregiranje pojedinih kućanstava i prostora u podesive cjeline za potrebe modeliranja. Glavne dvije dimenzije sustava zoniranja su broj zona i njihova veličina. Što je veći broj zona, to su manje veličine za pokrivanje istog područja istraživanja. U prošlosti je bila uobičajena praksa posebno razvijati sustav zoniranja za svaku studiju i kontekst donošenja odluka. To je očigledno rasipno ako se provede nekoliko studija u srodnim područjima. Štoviše, uvođenje različitih sustava zoniranja otežava se korištenje podataka iz prethodne studije i usporedbe rezultata modeliranja tijekom vremena.

Dijelovi izvan područja istraživanja obično su podijeljeni na nekoliko vanjskih zona. U nekim slučajevima može biti dovoljno razmotriti svaku vanjsku zonu kao "ostatak svijeta" u određenom smjeru. Područje istraživanja također je podijeljeno na manje unutarnje zone. Njihov će broj ovisiti o kompromisu između niza kriterija. Na primjer, sheme analize upravljanja prometom će općenito zahtijevati manje zone, koje često predstavljaju čak i parkirališta ili druge velike generatore/atraktore putovanja. Strateške studije, s druge strane, često će se provoditi na temelju većih zona.

Zone su u računalnim modelima prikazane na način da su sve njihove osobine i svojstva koncentrirane u jednoj točki koja se zove centroid. Ono se zapravo ne nalazi na nekoj fizički određenoj lokaciji na karti, već se koriste isključivo iz praktičnih razloga kodiranja. Centroidi se priključuju na mrežu putem konektora koji predstavljaju prosječne troškove (vrijeme, udaljenost) pridruživanja transportnom sustavu za putovanja s podrijetlom ili odredištem u toj zoni. Oni trebaju biti u blizini prirodnih pristupnih/izlaznih točaka za same zone.

Veličina zone mora biti takva da greška agregacije uzrokovana pretpostavkom da su sve aktivnosti koncentrirane u centroidu nije prevelika. Moglo bi biti prikladno započeti s postuliranjem sustava mnogo malih zona, jer se to može agregirati na različite načine kasnije ovisno o načinu vrednovanja projekta.

Sustav zoniranja mora biti kompatibilan s drugim administrativnim podjelama, osobito s popisom stanovništva zone, ovo je vjerojatno temeljni kriterij. Zone trebaju biti što je moguće više homogene u njihovoj namjeni zemljišta i/ili sastavu stanovništva.

Granice zona moraju biti kompatibilne s kordonima i linijama prethodnih sustava zoniranja. Međutim, u praksi je utvrđeno da korištenje glavnih cesta kao granica zone bi trebalo izbjegavati jer to stvara znatne poteškoće pri raspoređivanju putovanja u zone, kada one potječu ili završavaju na granici između dvije ili više zona. Oblik zona bi trebao omogućiti lako određivanje njihovih konektora. Ovo je osobito važno za kasniju procjenu unutarzonskih obilježja. Poželjno je raditi manje zone u zagušenijim područjima zbog više razine detaljnosti. [2]

Pregled broja zona na primjerima prometnih studija nekih gradova prikazan je u Tablici 1.

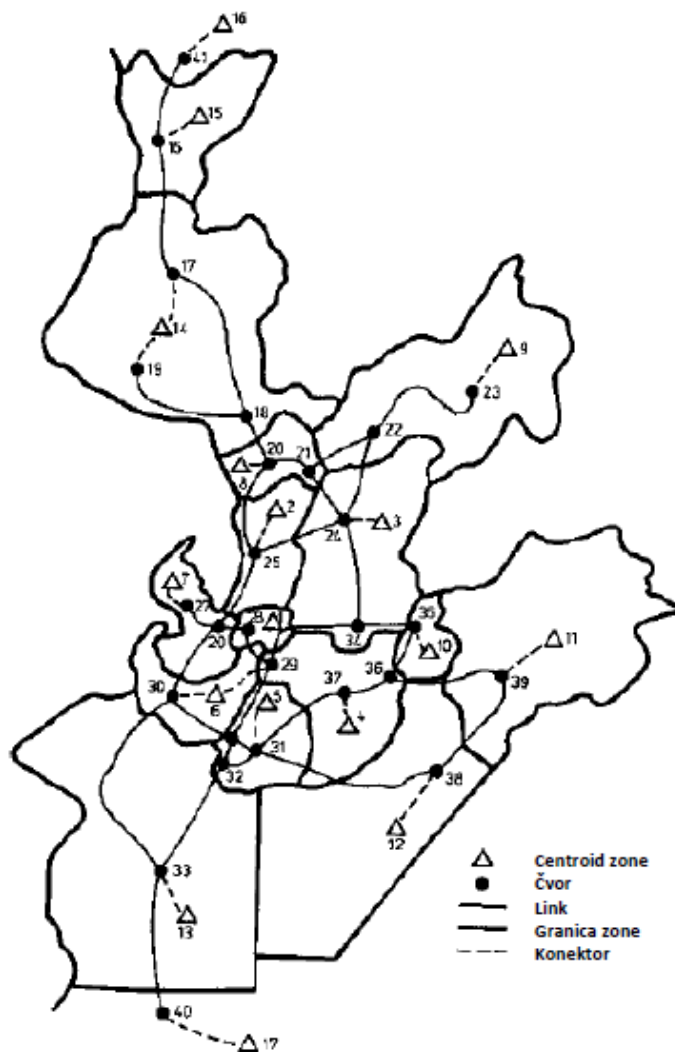
**Tablica 1. Pregled broja zona na primjerima prometnih studija nekih gradova [1]**

Grad	Broj stanovnika [milijuni]	Broj zona
London (2006)	7,2	2.252
Montreal (2008)	3,4	1.425
Leeds UK (2009)	0,7	560
Santiago (2009)	5,5	700
Dallas (2008)	6,5	4.875
Washington DC (2008)	6,5	2.200
Bogota (2000)	6,1	637
Dublin (2010)	1,7	650
Sydney (2006)	3,6	2.690

### 3.4.2. Izrada cestovne mreže

Smatra se da prometna mreža predstavlja ključnu komponentu na strani ponude prilikom izrade modela, tj. ono što transportni sustav nudi da zadovolji potrebe za putovanjima u studiji područja. Opis prometne mreže u računalnom modelu može se provesti pri različitim razinama detaljnosti i zahtijeva specifikaciju njegove strukture, njegovih svojstava ili atributa i odnosa između tih svojstava i prometnih tokova.

Praksa je modelirati mrežu kao sustav nodova (čvorova) i linkova (veza), gdje većina čvorova predstavljaju križanja, a linkovi homogene dionice ceste između križanja (Slika 15.). Veze karakterizira nekoliko atributa kao što su duljina, brzina, broj traka i drugi. Trenutno su glavni izvori mrežnih podataka brojne digitalne karte dostupne za većinu gradova. Međutim, ne treba pretpostavljati da su bez pogreške. Trebat će provjeravati, ažurirati, izdvajati (usredotočiti se na područje interesa) i nadopunjavanje opažanjima o stavkama kao što su parkiranje na ulici, utjecaj pješaka, autobusne trakove i druge značajke koje mogu utjecati na model. [2]



**Slika 15. Cestovna prometna mreža - sustav čvorova i linkova [1]**

Koliko se koristi atributa linkova ovisi o detaljnosti mreže i o vrsti korištenog modela. Minimum podataka za svaku vezu treba uključivati njezinu duljinu, brzine kretanja (brzine slobodnog protoka ili promatrane vrijednosti za danu razinu protoka) i kapaciteta, najčešće u jedinicama putničkog automobila po satu.

Detaljnije razrađeni modeli koriste povezuju vremena čekanja s protokom prometa, ali oni zahtijevaju dodatne informacije o linkovima, kao na primjer:

- vrsta ceste (npr. autocesta, magistrala, lokalna ulica).
- širina ceste i broj traka
- naznake o autobusnim trakovima ili zabrana korištenja određenih trakova za određena vozila
- zabrane skretanja i/ili okretanja




- tipovi raskrižja i podaci o raskrižju uključujući signalne planove
- kapacitet prometnica za vozila koja zauzimaju prostor u repu čekanja [2]

### 3.5. Generiranje putovanja

#### 3.5.1. Značajke putovanja

Model generiranja ili nastajanja putovanja primjenjuje se za procjenu broja putovanja koja počinju ili završavaju u određenoj prometnoj zoni koja se analizira.

Model generiranja putovanja ima za cilj procijeniti ukupni broj putovanja koje generira izvor  $O_i$  (eng. *Origin*) i privlači odredište  $D_j$  (eng. *Destination*) svake zone u analiziranom području (Slika 16).



**Slika 16. Generiranje putovanja [1]**

Analizirano područje podijeljeno je u prometne zone koje predstavljaju prostorne, geografske jedinice homogenih obilježja (eng. *Traffic Analysis Zone - TAZ*).

Putovanja se, s obzirom na **područje obuhvata**, mogu podijeliti na:

- unutarnja putovanja
- vanjska putovanja

Unutarnja putovanja predstavljaju sva putovanja koja se ostvaruju unutar promatranog područja, a mogu biti unutarzonska i međuzonska.

Vanjska putovanja predstavljaju sva ona putovanja kojima je barem jedan kraj putovanja (izvorište ili odredište) izvan područja koje se analizira. Takva putovanja mogu biti ulazna, izlazna i prolazna (tranzitna).

**Putovanje (eng. Trip or Journey)** je kretanje u jednom smjeru od točke izvorišta (O) do točke odredišta (D). Primarno se odnosilo na motorizirani promet (privatni/osobni i javni) najčešće s granicom najkraće udaljenosti od 300 metara, no s vremenom je na značenju dobio i nemotorizirani promet kojemu se daje sve veći značaj (pješačenje, bicikliranje).

Za **putovanja bazirana na kućanstvu (eng. Home-based Trip, HB)**, kućanstvo predstavlja bilo izvorište, bilo odredište putovanja. U većini studija, za posjetitelje iz drugih gradova njihov hotel se podrazumijeva kao privremeni dom.

**Putovanja koja nisu bazirana na kućanstvu (eng. Non-home-based Trip, NHB)** su putovanja u kojima niti završetak putovanja ne predstavlja kućanstvo putnika.

**Produkcija putovanja (eng. Trip Production)** je nastajanje putovanja

**Atrakcija putovanja (eng. Trip Attraction)** je atrakcija, privlačenje putovanja

**Generiranje putovanja (eng. Trip Generation)** je procjena ukupnog broja putovanja putnika s određenom svrhom koje će početi ili završiti u određenom području analize prometa (prometne zone). [1]

Podjela putovanja s obzirom na **vrijeme putovanja**:

- putovanja u vršnom razdoblju
- putovanja u izvanvršnom razdoblju

S obzirom na jutarnje i večernje vršno i izvanvršno razdoblje, često se uzima u obzir odnosno podrazumijeva da večernja vršna i izvanvršna razdoblja predstavljaju zrcalnu sliku jutarnjeg vršnog i izvanvršnog razdoblja.

Podjela putovanja s obzirom na **značajke pojedinca**:

osobni dohodak (najčešće tri kategorije):

- nizak prihod
- srednji prihod
- visoki prihod

posjedovanje automobila (najčešće tri kategorije):

- 0 automobila
- 1 automobil
- 2 ili više automobila

veličina kućanstva i struktura (npr. šest kategorija u britanskim studijama).

Čimbenici koji utječu na **produkciju osobnih putovanja**:

- osobna novčana primanja
- posjedovanje automobila
- veličina obitelji
- struktura kućanstva
- vrijednost zemljišta
- gustoća područja stanovanja
- dostupnost

Čimbenici koji utječu na **atrakciju osobnih putovanja**:

- nisu istraženi u velikoj mjeri
- najčešće se odnose na značajke zemljišta zone, industrijske, komercijalne i druge usluge

Čimbenici koji utječu na **produkciju i atrakciju teretnog prometa**:

- broj zaposlenih
- ukupna prodaja
- natkriveno područje tvrtke
- ukupno područje tvrtke [1]

### 3.5.2. Podmodel generiranja putovanja u programskom alatu PTV Visum

- Nakon što se u potpunosti izradi prometna mreža područja obuhvata u koristeći programski alat PTV-Visum, pristupa se upisivanju vrijednosti atributa za svaku pojedinu zonu. Broj atributa određuje se proizvoljno. Za potrebe ovog rada koristili su sljedeći atributi: broj kuća
- broj stanova
- produkcija

atrakcija

**Broj kuća i broj stanova** su atributi koji su definirani demografskim podacima dostupnim na internetu i koriste se isključivo za stambene zone. Podaci o **produkciji i atrakciji** se koriste za zone koje stvaraju ili privlače velik broj putovanja. Naravno, visoka preciznost potonjih bi se postigla isključivo brojanjem prometa i anketiranjem.

Nakon što su kreirani atributi, upisuju se u dijaloški okvir za svaku zonu kao što je prikazano na Slici 17.

Number 2

Type 0

Code

Name Naziv zone

OD demand | DStrata | User-defined attributes

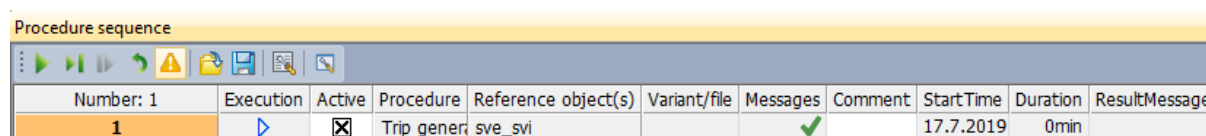
Attribute	Value
broj_kuca	0
broj_stanova	0
produkcija	0
atrakcija	0

Show all Rows OK Cancel

Slika 17. Umetanje atributa zone

Prilikom izvođenja podmodela generiranja putovanja, softver će pomnožiti unesene podatke sa koeficijentima zadanim u formuli od strane izrađivača i prema tome dobiti konačne vrijednosti produkcije i atrakcije po zonama.

Ukoliko je radnja uspješno izvršena softver će o tome obavijestiti kao na Slici 18.



Number: 1	Execution	Active	Procedure	Reference object(s)	Variant/file	Messages	Comment	StartTime	Duration	ResultMessage
1		<input checked="" type="checkbox"/>	Trip gener	sve_svi				17.7.2019	0min	

**Slika 18. Generiranje putovanja, procedure sequence (Visum)**

### 3.6. Distribucija putovanja

Modeli generiranja putovanja mogu se koristiti za procjenu ukupnog broja putovanja iz zone (podrijetla, proizvodnje) u svaku zonu (destinacije, atrakcije). Produkcija i atrakcije pružaju ideju o količini putovanja u istraživanom području, ali to je rijetko dovoljno za modeliranje i donošenje odluka. Potrebna je bolja predodžba o putovanjima, gdje se odvijaju, odabrani načini prijevoza te rute kojima se ostvaruju.

Iz toga proizlazi sljedeći korak, distribucija putovanja. Cilj ovog koraka je dobiti OD matricu putovanja (OD = *Origin Destination*) određenog vremenskog intervala (npr. vršnog sata).

Dvodimenzionalna matrica koja se sastoji od ćelija gdje reci i stupci predstavljaju svaku od zona u području istraživanja (uključujući i vanjske zone).

Ćelije u svakom retku i sadrže putovanja podrijetlom iz te zone koja imaju kao odredišta zone u odgovarajućim stupcima. Glavna dijagonala odgovara unutarzonskim putovanjima.

Matrice mogu biti dodatno raščlanjene prema aktivnostima koje se provode (posao, škola, fakultet, rekreacija), vrsti putnika (studenti, radnici, umirovljenici) i modu prijevoza (osobni, javni, etc.). [1]

#### 3.6.1. Generalizirani trošak putovanja

Jedan od bitnih čimbenika koji utječe na distribuciju putovanja jest relativni trošak putovanja između zona.

Ovaj element troškova može se shvatiti u smislu jedinice prijedene udaljenosti, vremena putovanja ili novčanih troškova.

Troškove putovanja ne treba razmatrati zasebno, nego ih je, kombinirajući sve prethodno navedene attribute, potrebno generalizirati, odnosno svesti na zajedničku mjernu jedinicu, a koja se naziva generalizirani trošak putovanja.

Generalizirani trošak putovanja predstavlja tipičnu linearnu funkciju atributa putovanja ponderiranu koeficijentima koji predstavljaju njihovu relativnu važnost iz perspektive putnika.

Generalizirani trošak putovanja može biti iskazan u vremenu, novcu ili nekoj drugoj jedinici.

$$C_{ij} = a_1 t_{ij}^v + a_2 t_{ij}^w + a_3 t_{ij}^t + a_4 t_{ij}^n + a_5 F_{ij} + a_6 \varphi_j + \delta \quad (3)$$

$t_{ij}^v$  – vrijeme putovanja provedeno u vozilu

$t_{ij}^w$  - vrijeme hodanja do i od stajališta javnog prijevoza ili parkirališta

$t_{ij}^t$  - vrijeme čekanja na stajalištu ili vrijeme provedeno u traženju parkirališnog mjesta

$t_{ij}^n$  - vrijeme presjedanja

$F_{ij}$  - troškovi prijevoza (prijevozna karta, troškovi goriva, naplata cestarine itd.)

$\varphi_j$  - troškovi terminala, odnosno parkiranja

$\delta$  - parametar koji prezentira sve ostale attribute koji nisu uključeni, npr. sigurnost, udobnost

$a_{1...6}$  - ponderi pridruženi svakom elementu troška, koji imaju vrijednost odgovarajuće konverzije svih atributa u novac ili vrijeme

### 3.6.2. Gravitacijski model

Gravitacijski model se najčešće primjenjuje za procjenu putovanja između zona. Ideja za nastajanje ovog modela proizašla je iz analogije s Newtonovim zakonom (sila privlačenja između dvaju tijela proporcionalna je masama tih tijela, a obrnuto proporcionalna kvadratu udaljenosti između njih).

Primjena u području prometnog modeliranja: interakcija između dviju zona ovisi o snazi generiranja odnosno privlačenja putovanja tih zona i njihovoj međusobnoj udaljenosti.

Opći oblik gravitacijskog modela: broj putovanja između izvorišne i odredišne zone proporcionalan je s mogućnošću produkcije izvorišne zone, mogućnošću atrakcije odredišne zone i faktorom koji ovisi o troškovima putovanja između tih zona.

Opći oblik (Casey 1955.):

$$T_{ij} = \frac{\alpha P_i P_j}{d_{ij}^2} \quad (4)$$

$\alpha$  - kalibracijska konstanta

$P_i, P_j$  - populacija zone  $i$ , odnosno zone  $j$

$D_{ij}$  – udaljenost između zona  $i$  i  $j$

Model prema Casey-u iz 1955. predstavlja prejednostavan model pa se koristi druga distribucijska funkcija koja prikazuje otpor putnika prema putovanju kako se povećavaju troškovi putovanja (npr. udaljenost, vrijeme putovanja):

$$T_{ij} = \alpha O_i D_j f(c_{ij}) \quad (5)$$

$f(c_{ij})$  - generalizirana distribucijska funkcija troškova putovanja

$c_{ij}$  - generalizirani trošak putovanja

$O_i$  – ukupan broj putovanja koji nastaju u zoni  $i$

$D_j$  – ukupan broj putovanja koja su privučena u zonu  $j$

Generalizirana distribucijska funkcija troškova putovanja sadrži jedan ili više parametara koje je potrebno kalibrirati, a pojavljuje se u nekoliko oblika i to kao:

- eksponencijalna funkcija  $f(c_{ij}) = \exp(-\beta c_{ij}) \quad (6)$

- funkcija potencije  $f(c_{ij}) = c^{-n} \quad (7)$

- kombinirana ili Tannerova funkcija  $f(c_{ij}) = c_{ij}^n \exp(-\beta c_{ij}) \quad (8)$

U praksi se najčešće koristi oblik gravitacijskog modela koji je uravnotežen po produkciji, a primjenom simulacijskih alata u više iteracija uravnotežuje se i po atrakciji:

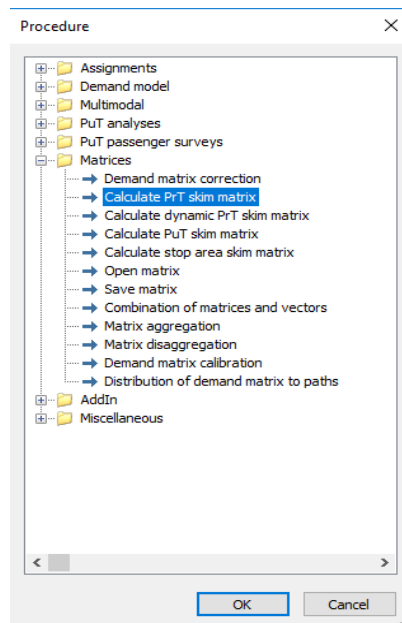
$$T_{ij} = \frac{O_i * D_j * f(c_{ij})}{\sum_{j=1}^n D_j * f(c_{ij})} \quad (9)$$

### 3.6.3. Podmodel distribucije putovanja u programskom alatu PTV Visum

Prije izrade OD matrice potrebno je kreirati SKIM matricu. Ona predstavlja generalizirane troškove putovanja između OD parova. Iz toga proizlazi da je za ovu fazu ključan izbor

parametara i njihovih pondera. Temeljem takve matrice, u fazi distribucije PTV-Visum će rasporediti putovanja između zona.

U dijaloškom okviru slijeda postupaka (Procedure sequence) potrebno je odabrati proračun SKIM matrice za privatni prijevoz (Calculate PrT skim matrix) kao na Slici 19.



**Slika 19. Kreiranje SKIM privatnog prijevoza**

Za referentno vozilo odabere se automobil (Car), a od ponuđenih SKIM matrica  $t_{Cur}$ , koja predstavlja vremena putovanja između zona preko linkova na koje je dodano prometno opterećenje.

Nakon što je izrađena matrica može se pristupiti distribuciji putovanja.

Odabere se opcija kreiranja distribucije putovanja te ju se postavlja na zadnje mjesto u proceduri. Ako raspored nije odgovarajući, softver ne može izračunati željene modele. To vrijedi sa svaki podmodel.

Za referentni objekt odabere se prethodno stvoreni stratum potražnje.

U dijaloškom okviru izvedbe operacije odabere se kreirana a SKIM matrica, kombinirana funkcija korisnosti te se unesu kalibracijski parametri. Označavanjem opcija doubly-constrained i Production total osiguravaju se dvostruka ograničenja matrice koja se inicijalno usklađuje po produkciji (Slika 20.)



	Demand stratum	Utility function	Function type	a	b	c	Direction parameters	
1	sve_svi	Matrix([NO] ...	Combined	00000	00000	00000	Productions, Doubly constrained ...	Matrix([DMODEL

**Slika 20. Dijaloški okvir za unos parametara distribucije putovanja**

Rezultat ovog koraka je OD matrica prostorne raspodjele putovanja.

### 3.7. Modalna razdioba putovanja

Modalna raspodjela putovanja (eng. Mode Choice; Modal Split) treća je faza klasičnog četverostupanjskog modela.

Izbor moda prijevoza predstavlja jedan od najznačajnijih klasičnih modela u procesu prometnog planiranja. Razlog tomu je što javni prijevoz ima značajnu ulogu u prometnoj politici.

Javni prijevoz omogućava korisnije i učinkovitije korištenje prostora namijenjenog cestovnom prometu nego što bi omogućio privatni prijevoz. Također, značajnije su društvene koristi (manje zagušenje, manji broj nesreća i sl.) Uporaba goriva je učinkovitija. S druge strane, privatni prijevoz je fleksibilniji, udobniji i dostupniji.

Pitanje načina izbora, vjerojatno je najvažniji element u prometnom planiranju i kreiranju prometnih politika. To utječe na opću učinkovitost s kojom se može putovati u urbanim područjima. Stoga je važno razvijati i koristiti modele koji su osjetljivi na te attribute putovanja koji utječu na pojedinačne odluke o izboru moda prijevoza.

Matrica putovanja (OD matrica) dobivene iz raspodjele putovanja raspodijeljena je na određeni broj matrica koje predstavljaju svaki mod prijevoza.

Čimbenici koji utječu na odabir vrste prijevoza mogu se podijeliti u tri grupe značajki:

1. Značajke putnika:

- posjedovanje osobnog automobila;
- posjedovanje vozačke dozvole;
- struktura kućanstva (mladi, par s djecom, umirovljenici, samci, itd.);
- dohodak;

- odluke donesene na nekom drugom mjestu, npr. nužnost korištenja osobnog automobila na poslu;
- gustoća stambenih jedinica.

## 2. Značajke putovanja:

- svrha putovanja – putovanje na posao je obično jednostavnije izvesti javnim gradskim prijevozom zbog njegove redovitosti;
- dio dana u kojem se ostvaruje putovanje – npr. noćna putovanja je teže ostvariti javnim gradskim prijevozom;
- je li se putovanje ostvaruje samostalno ili s drugim putnicima.

## 3. Značajke prometnog sustava:

- komponente vremena putovanja: vrijeme u vozilu, vrijeme čekanja i vrijeme pješaćenja do svakog moda prijevoza.
- komponente novčanih troškova
- dostupnost i troškovi parkiranja;
- pouzdanost vremena putovanja i redovitost usluge;
- udobnost i praktičnost;
- sigurnost vožnje i zaštita tijekom vožnje;
- zahtjevi za vozačkim vještinama;
- mogućnosti provođenja drugih aktivnosti tijekom vožnje. [1]

### 3.7.1. Multinomijalni logit modeli

Multinomijalni modeli koriste se u slučajevima kada je skup varijanti  $C_n$  sastavljen od više varijanti (Slika 21.). Koriste se i binarni logit modeli, ali isključivo kada su na raspolaganju samo dva moda prijevoza, što je u praksi vrlo rijetko. Binarni logit model najjednostavniji je oblik diskretnih modela odabira. Za potrebe ovog rada opisan je ipak češće korišten multinomijalni model.



Slika 21. Modalna razdioba putovanja [1]

Skup C može se sastojati od sljedećih elemenata:

- a) vožnja automobilom - sam vozač
- b) zajednička vožnja automobilom
- c) taxi
- d) motocikl
- e) bicikl
- f) pješaćenje
- g) autobus
- h) željeznica

Itd.

Obrazac za proračun multinomijalnog logit modela:

$$P_n(i) = \frac{e^{\mu V_{in}}}{\sum_{j \in C_n} e^{\mu V_{jn}}} \quad (10)$$


gdje su:

$C$  – skup svih potencijalnih varijanata

$j$  – broj elemenata skupa

### 3.7.2. Podmodel modalne razdiobe putovanja u programskom alatu PTV Visum

U dijaloškom okviru slijeda postupaka (Procedure sequence) potrebno je odabrati proračun modalne razdiobe putovanja (Mode choice) kao na Slici 22.



**Slika 22. Kreiranje dodjele putovanja privatnog prijevoza**

Zatim se odabere referentni objekt koji u ovom podmodelu podrazumijeva model potražnje. Najčešće se odabire prethodno definirani vršni sat, u kojem se zatim odabire stratum potražnje za koji se izvodi modalna razdioba.

U dijaloškom okviru izvedbe operacije unose se parametri podmodela prema kojima se podmodel izvodi. Prvo se unosi formula korisnosti koju se odabire temeljem istraživanja ili prethodnih iskustava. Neizostavno se unose i ostali podaci: vrsta funkcije, kalibracijski parametri te ulazne i izlazne matrice (Slika 23.)

Parameters: Mode choice									
<input checked="" type="checkbox"/> Set any result demand matrix to 0 prior to calculation									
Key	Demand stratum	Mode	Utility function	Function type	a	b	c	Input demand matrix	Input demand matrix
1 sve_sv/C	sve_svi	C Car	$-0.06 * \text{Matrix}([NO] = 1) - 2$	Logit	0	0	1	...	Matrix(2)
2 sve_sv/PuT	sve_svi	PuT PuT	$-0.0006 * \text{Matrix}([NO] = 3) - 0.02 * \text{Matrix}([NO] = 10) - 0.02 * \text{Matrix}([NO] = 11) + 1$	Logit	0	0	1	...	Matrix(2)
								2 Distribution sve_svi	Matrix(17)
								2 Distribution sve_svi	Matrix(18)

**Slika 23. Unos podataka za izvršenje modalne razdiobe**

Za uspješno izvršenje ovog koraka potrebna je već unesena ponuda javnog prijevoza te izrađene potrebne matrice.

### 3.8. Dodjeljivanje putovanja na mrežu

Prema četverostupanjskom modelu iza faze modalne razdiobe putovanja slijedi posljednja faza dodjeljivanja (asignacije) putovanja na mrežu.

Dodjeljivanje putovanja na mrežu daje konačnu sliku modela jer su putovanja raspoređena po rutama. Stoga se može reći da ova faza odgovara na pitanje kojom rutom se odvijaju putovanja. Reprezentativnost izlaznih podataka će najviše ovisiti o kvaliteti i kvantiteti ulaznih podataka.

Obvezni ulazni podaci za provođenje dodjeljivanja putovanja simulacijskim alatom su:

- OD matrica putovanja između zona;
- izrađena prometna mreža;
- značajke elemenata prometne mreže (linkovi i čvorovi);
- model odabira rute putovanja.

Izlazni podaci nakon provođenja dodjeljivanja putovanja su:

- rute putovanja
- značajke ruta (vrijeme putovanja, udaljenosti, troškovi);
- prometno opterećenje ruta;
- prometno opterećenje linkova i čvorova.

Osnovna premisa u dodjeljivanju putovanja je pretpostavka racionalnog putnika.

Racionalni putnik je onaj putnik koji do odredišta odabire rutu za koju percipira najmanje troškove putovanja.

Utvrđeno je da kombinacija vremena putovanja i udaljenosti daje najbolje rezultate, ali je uspješnost u odabiru optimalne rute na temelju ta dva kriterija od 60% do 80%.

S obzirom da je utjecaj drugih faktora na odabir optimalne rute vrlo malen, uzroci ovog odstupanja se mogu pripisati različitoj ljudskoj percepciji, nedovoljnim informacijama o troškovima rute i nekim drugim greškama.

Činjenica da različiti vozači odabiru različite rute putovanja između istih izvorišta i odredišta putovanja proizlazi iz sljedećih razloga:

- Razlike u individualnoj percepciji o tome što čini najbolju rutu: neki žele minimizirati vrijeme putovanja, neki potrošnju goriva itd.
- Razina znanja o mogućim varijantnim rutama do odredišta je različita između putnika.

Za dodjeljivanje putovanja mrežu najčešće se koriste:

1. Metoda „sve ili ništa“
2. Stohastička metoda
3. Ekvilibrirana metoda
4. Metoda dinamičkog dodjeljivanja putovanja [1]

**Metoda sve ili ništa** je najjednostavnija jer pretpostavlja kako na promatranoj mreži nema prometnih zagušenja te kako svi vozači jednako uočavaju troškove putovanja na različitim rutama između izvorišta i odredišta.

Jedna je od osnovnih zamjeraka visoka razina nestabilnosti modela jer male promjene na prometnoj mreži mogu izazvati velike promjene u izlaznom rezultatu, odnosno u prometnom opterećenju linkova.

**Stohastička metoda** temelji se na promjenjivosti vozačevih uočavanja troškova putovanja.

Ova metoda mora uzeti u obzir i druge rute putovanja između izvorišta i odredišta putovanja.

Prema **ekvilibriranoj metodi**, postignut je ekvilibrij onda kada putnici više ne mogu naći troškovno povoljniju rutu između izvorišta i odredišta putovanja od one koju trenutno koriste. Ova metoda se najčešće koristi za modeliranje zagušene prometne mreže urbanih sredina te je zbog toga izabrana i detaljno opisana u ovom radu.

**Dinamički modeli** koriste realističniju pretpostavku da su izvorišno-odredišna potražnja i značajke linkova varijabilni u promatranom vremenu.

### 3.8.1. Ekvilibrirana metoda

Ova metoda se najčešće koristi u slučajevima zagušene prometne mreže u urbanim sredinama, a temeljena je na ograničenom kapacitetu linkova prometne mreže te na funkciji trošak – prometni tok.

Metodu je prvi predložio Wardrop te je i temeljena na Wardropovom prvom principu kojem se teži i koji glasi: „U uvjetima ekvilibrija promet se raspoređuje po linkovima zagušene

prometne mreže tako da sve iskorištene rute između OD parova imaju iste i minimizirane troškove, dok sve neiskorištene rute imaju veće ili iste troškove.“

Beckmann je predložio model matematičkog programiranja za postizanje Wardropovog principa. On predlaže minimizaciju funkcije cilja  $Z\{T_{ijr}\}$  uz ograničenja temeljena na značajkama prometnog toka. Ova funkcija zapravo predstavlja zbroj svih površina ispod krivulje trošak-prometni tok za sve linkove mreže.


$$\text{Min } Z\{T_{ijr}\} = \sum_a \int_0^{Q_a} c_a(q) dq \quad (11)$$

uz ograničenja:

$$\sum_r T_{ijr} = T_{ij} \quad (12)$$

$$T_{ijr} \geq 0 \quad (13)$$

Ovaj se Beckmannov minimizacijski problem može objasniti time da je potrebno pronaći prometno opterećenje  $Q_a$ , takvo da je zbroj odgovarajućih površina ispod funkcije trošak (vrijeme putovanja) prometni tok minimalan. Problem je prikazan grafički na Slici 24. [1]



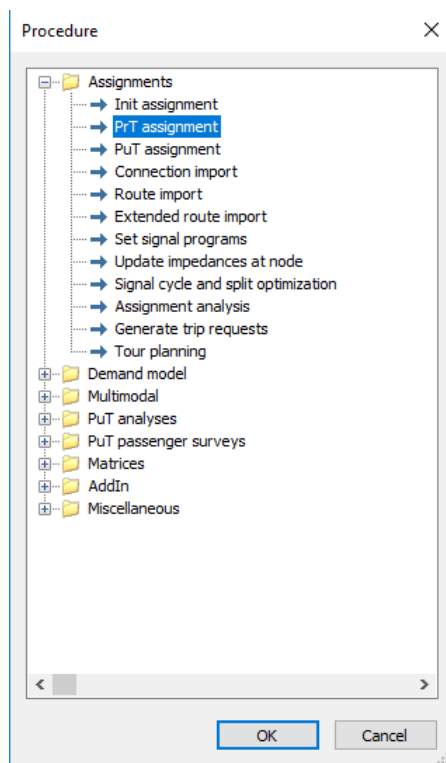
**Slika 24. Grafički prikaz ekvilibrirane metode [1]**

Na Slici 24. vodoravna os predstavlja ukupan broj putovanja između A i B,  $T_{AB}$ . Taj broj treba biti raspodijeljen između linkova 1. i 2. tako da je vrijeme putovanja (ovisno o prometnom opterećenju  $q$ ) jednako (Wardropov prvi princip – ako to ne bi bilo zadovoljeno,

vozila bi se kretala samo po jednom linku). Kako bi se točka ekvilibrija mogla prikazati grafički, krivulje vrijeme putovanja – prometni tok su prikazane jedna nasuprot drugoj. Ekvilibrij prometnih tokova  $q_e$  postiže se u točki u kojoj se sijeku dvije funkcije jer je u toj točki površina ispod funkcija od 0 do  $q_e$  minimalna. Bilo koji drugi odabrani  $q$  lijevo ili desno od točke  $q_e$  (na primjer  $q'$ ) zauzimao bi veću površinu ispod krivulja, a to bi značilo uklanjanje toga linka na putovanju između točaka A i B.

### 3.8.2. Podmodel dodjeljivanja putovanja u PTV Visum-u

U dijaloškom okviru slijeda postupaka (Procedure sequence) potrebno je odabrati proračun dodjeljivanja putovanja ovisno o modu prijevoza (PrT assignment ili PuT assignment). Primjer odabira za PrT prikazan je na Slici 25.

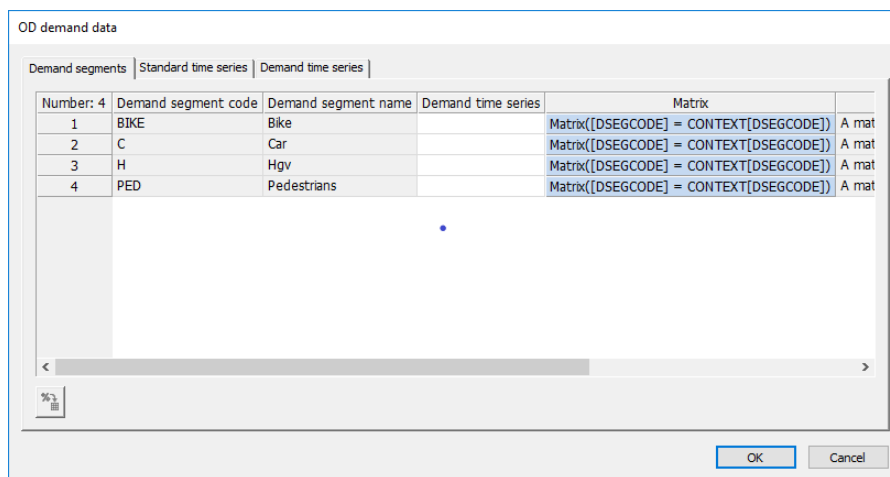


**Slika 25. Kreiranje dodjele privatnog prijevoza**

Zatim se odabere referentni objekt koji također ovisi o modu prijevoza za koji se izvodi dodjela putovanja na mrežu, a za metodu (Variant/file) ovog rada odabrana je ekvilibrirana metoda (Equilibrium assignment).

U dijaloškom okviru segmenata potražnje (demand segments) potrebno je označiti pripadajuće matrice po modovima prijevoza (Slika 26).





**Slika 26. Izbor matrica prema segmentima potražnje**

Ukoliko je dodjela putovanja na mrežu uspješno izvršena, prometno opterećenje se može jasno vidjeti u Network editor-u.

## **4. IZRADA MODELA GRADA SPLITA**

### **4.1. Opći podaci i prometne značajke grada Splita**

Grad Split je veličinom drugi grad u Republici Hrvatskoj i najveći hrvatski grad na istočnoj obali Jadranskog mora smjestio se između rijeka Žrnovnice na istoku i Jadra na zapadu.

Split je važno hrvatsko, mediteransko kulturno središte, po veličini danas i drugi sveučilišni centar u Hrvatskoj, a poslije Zagreba ima i najveći broj diplomatskih, konzularnih, odnosno predstavništava međunarodnih organizacija u Hrvatskoj.

Split, kao grad na moru i jedna od najznačajnijih turističkih destinacija u Hrvatskoj posjeduje i snažnu brodograđevnu industriju te razvijeno građevinsko poduzetništvo, ali i prerađivačku industriju. Split je i središte informatičke djelatnosti te sjedište jednoga od najvećih trgovinskih lanaca u Hrvatskoj. [9]

Do sada su izrađene brojne prometne studije i projekti u cilju poboljšanja prometnog sustava grada Splita. [10] [11]

#### **4.1.1. Geografski i prometni položaj**

Split je smješten na jadranskoj obali u srednjoj Dalmaciji na Splitskom (Marjanskom) poluotoku. Od uzvisina, okružuju ga u zaleđu sa sjevera i sjeveroistoka planina Mosor, sa sjeverozapada brdo Kozjak, s istoka brdo Perun, a najstarija gradska jezgra se nalazi podno brda Marjana, koje se nalazi zapadno od stare gradske jezgre. Splitski poluotok okružuju otoci Brač, Hvar, Šolta i Čiovo. Trajekti iz luke Split često su jedina veza otoka srednje Dalmacije s kopnom.

Svi dijelovi grada Splita su povezani gustom mrežom autobusnih linija. Na usluzi putnika, osim, gradskih autobusnih linija stoji na raspolaganju više od 30 linija prigradskog i šireg gradskog prometa. Autobusni promet na području grada Splita i okolice je podijeljen na četiri tarifne zone. [12]

Od utorka 11. lipnja 2019. godine počeo je prometovati takozvani „gradski metro“ na relaciji od Kopilice do Trajektna luke kao dio integriranog javnog prijevoza grada Splita. Ističe se da svi korisnici javnog gradskog prijevoza imaju mogućnost s istom putnom kartom koristiti i autobuse javnog gradskog prijevoza „Promet d.o.o.“, kao i „gradski metro“ na navedenoj

relaciji. Nova usluga „gradskog metroa“ pruža posebne pogodnosti putnicima koji koriste linije broj 31, 33, 34, 35, 36, 37, 38, 67, 69, 71, 73, 76, 77, 80, 81, 86, i 91 koji u Kopilici mogu izvršiti presjedanje na „gradski metro“ čime izbjegavaju prometna zagušenja do Terminala Sukoišan te tako brže mogu doći do Trajektna luke, odnosno centra grada. [13]

Željeznički kolodvor smješten je uz glavni autobusni kolodvor i trajektna luku u centru grada pa time ta tri terminala sa stajališta putnika imaju izvrsnu lokaciju i međusobnu povezanost što putnicima odnosno korisnicima prijevozne usluge olakšava prilikom korištenja više modova prijevoza.

Trajektna luka Split smještena je na izuzetnoj geografskoj poziciji na Mediteranu, jedno je od najvažnijih središta za lokalni i međunarodni pomorski promet. Sa godišnjim prometom većim od 3 milijuna putnika i 600.000 vozila, splitska luka je treća luka na Mediteranu (poslije Napulja i Pireja). [14]

Zračna luka Split bilježi konstantan porast prevezenih putnika koji je u 2019. godini iznosio 3.124.067 putnika te predstavlja jedan od važnijih gradskih generatora putovanja. [15]

#### **4.1.2. Turizam**

Split posljednjih godina postaje sve popularnije turističko odredište. Prema podacima ECM-a (European Cities Marketing), organizacije koja okuplja oko 120 velikih turističkih gradova Europe, Split je imao najveći godišnji postotak rasta broja dolazaka i noćenja turista. Postao je turistička hit destinacija, posebno mladih te postao turistički prvak Hrvatske. U prvih 9 mjeseci 2014. godine ostvarene su 863.000 noćenja, što je za 33.000 više nego 2013. godine [9]. Prosjek zadržavanja turista u Splitu je 3,5 dana. Najviše ih dolazi iz Njemačke. Slijede Britanci i Francuzi te Talijani, potom gosti iz SAD-a i Australije. Sa skoro milijun ostvarenih noćenja turista godišnje Split je zakoračio na europsku i svjetsku turističku pozornicu traženih destinacija. Dovođenjem započelih te izgradnjom novih hotelskih kapaciteta, Split će se jače pozicionirati na tržištima kongresnog, sportskog, rekreacijskog i kulturnog turizma. Procjenjuje se da bi tako za 10-ak godina mogao doseći 2 milijuna noćenja. Za uređenje grada, kao i za ukupnu turističku ponudu Split je dobio niz najznačajnijih domaćih i međunarodnih nagrada turističkih, gospodarskih i drugih asocijacija.

#### 4.1.3. Demografski pokazatelji

Prema posljednjem popisu stanovništva, iz 2011. godine Split ima 178.192 stanovnika, što je skoro 40% žitelja Splitsko dalmatinske županije (455.242 stanovnika), odnosno nešto više od 4 posto ukupnog broja stanovnika Republike Hrvatske (4.290.612 stanovnika). Prema podacima Hrvatskog zavoda za mirovinsko osiguranje, u Splitu je 30. lipnja 2013. godine bilo registrirano 84.679 zaposlenih osoba. Od toga je 73.881 bio zaposlen kod pravnih osoba. Udio žena u broju zaposlenih je 49,24%. Prema podacima Područne službe Hrvatskog zavoda za zapošljavanje 29. veljače 2014. godine u Splitu je bilo registrirano 20.572 nezaposlenih. Među nezaposlenima, prema razini obrazovanja dominiraju osobe sa srednjom stručnom spremom (68,3%). Čak 14,7% nezaposlenih ima visoko obrazovanje (fakultet, akademiju, magisterij ili doktorat). Udio onih sa završenom višom školom, prvim stupnjem fakulteta i stručnim studijem je 8,0%, a onih sa osnovnom školom 14,8%. Bez škole je samo 1,1%. Među nezaposlenima je 55,7% žena. [9]

#### 4.1.4. Gospodarstvo

Unatoč globalnoj krizi Split tradicionalno zadržava vitalnost. Ona se ogleda kako u jačanju položaja grada kao turističke destinacije, rastu prometne frekventnosti, tako i u poduzetničkoj inovativnosti, poticanju malog poduzetništva, školovanju za deficitarna zanimanja potrebna lokalnom gospodarstvu te stalnom poticanju razvoja Sveučilišta.

Split, kao dalmatinska metropola i aglomeracijsko središte, kulturni, privredni, sveučilišni i sportski centar ima velike prostorne, stručne, znanstvene i proizvodne potencijale koji uz korištenje sredstava iz europskih fondova predstavljaju okosnicu budućeg razvoja grada, čime bi trebao postati i lokomotiva razvoja regije. U funkciji razvoja grad je profilirao i snažniju aktivnost na međunarodnom planu u funkciji privlačenja stranih investitora, za koje se očekuje da će se uključiti u realizaciju predviđenih gradskih projekata, čija vrijednost se mjeri u stotinama milijuna eura. Vezano s tim jasno je izraženo opredjeljenje na snažan razvoj grada kao turističke destinacije, s osloncem na kulturno – povijesnu baštinu i nove projekte kojima se već privlače desetine tisuća novih turista, koji rezultati se već vide u protekloj i ovoj godini kada je Split srušio sve rekorde u posjećenosti u sezoni.

Funkcioniranje grada, njegovih upravnih i komunalnih službi te razvoja u 2014. godini financira se iz proračuna, koji je iznosio 840.521.290 kuna. I iz samog proračuna se da

iščitati u kojem je pravcu usmjeren razvoj, s obzirom da je proračun za kulturu povećan sa 80,45 milijuna kuna u 2013. g. na 85,24 milijuna kuna u 2014. godini.

Do 1990. godine, Split je imao razvijenu tekstilnu, kemijsku i metaloprerađivačku industriju, brodogradnju te, uz turističku djelatnost, snažan građevinski sektor. Danas okosnicu gospodarstva čine brodogradnja, trgovina, sajamska djelatnost te razvoj novih tehnologija. Uz podršku grada otvoren je Microsoftov inovacijski centar, drugi u Hrvatskoj, koji je dio Microsoftove „unlimited potential“ inicijative s ciljem povezivanja informatičkih grana i stručnjaka radi stvaranja novih proizvoda i njihovog plasiranja na tržište. Centar je dio mreže od 130 takvih centara u svijetu, što mu omogućuje pristup nizu projekata, znanja i mogućnosti. Namijenjen je malim i srednjim poduzećima kojima osigurava infrastrukturu i resurse potrebne za razvoj inovativnih softverskih rješenja i usluga, njihovo testiranje. Tu je i najznačajnija podružnica kompanije „Ericsson Nikola Tesla“ koja se bavi razvojem informacijskih i komunikacijskih tehnologija i koja ima uspješnu dugogodišnju suradnju sa splitskim Fakultetom elektrotehnike, strojarstva i brodogradnje. U Splitu djeluje i Tehnološki centar Split d.o.o., koji pruža različite vrste stručnih usluga, koji zajedno s malim tvrtkama koriste prostor od oko 800m<sup>2</sup>. U svrhu komercijalizacije ideja i povezivanja sveučilišta i poduzetništva, osnovan je Ured za transfer tehnologije, koji je dio Centra za znanstveno-tehnologijski razvitak Sveučilišta u Splitu. Grad ulaže napore da postane središtem kulturnih, zabavnih, sportskih, te gospodarskih manifestacija, što za cilj ima povećanje turističke atraktivnosti Splita, promociju proizvođača i njihovih proizvoda te upisivanja Splita na sajamsku kartu Europe. Tako se izravno potiče niz međunarodnih sajмова među kojima su GAST i SASO (sajam gastro turizma i sajam graditeljstva), najveći u Hrvatskoj te zadržavaju stabilnost po broju sudionika unatoč krizi, Croatia Boat Show, jedan od najvećih europskih sajмова takve vrste, potom Praznik cvijeća, Međunarodna konferencija o softveru, telekomunikacijama i računalnim mrežama Softcom i brojni drugi. Grad te manifestacije, osim financijski potiče i omogućavanjem povoljnijeg korištenja javnih gradskih površina. Također, donošenjem planskih dokumenata otvara prostor za oživljavanje građevinskog sektora, primjerice stvaranjem pretpostavki za izgradnju stanova u poticajnoj stanogradnji (POS).

Grad sudjeluje u razvoju gospodarstva grada i potporama malom gospodarstvu radi poticanja konkurentnosti i inovativnosti. Suraduje i sa lokalnim i regionalnim partnerima, usmjeravajući svoje djelovanje ka postizanju ciljeva nacionalnih i europskih strategija razvoja gospodarstva.

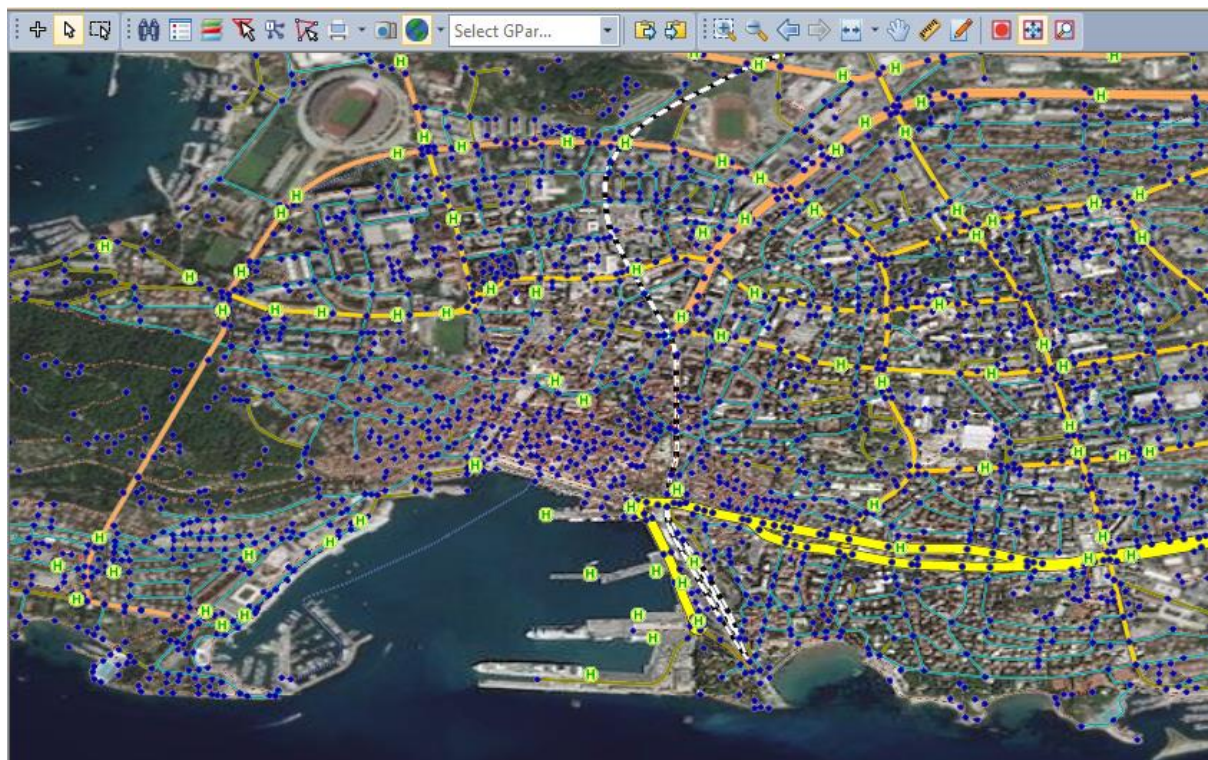
Ujedno, aktivno se radi na poticanju razvoja poduzetništva, cjeloživotnog obrazovanja, održivog razvoja, povlačenju sredstava iz europskih fondova te poticanju razvoja turizma. [9]

## 4.2. Izrada mreže

### 4.2.1. Izrada elemenata mreže

Prvi korak u izradi mreže napravljen je učitavanjem geoinformacijskog sustava, Open Street Map (OSM) datoteke u PTV-Visum s cijelom prometnom mrežom i pripadajućim podacima o linkovima i čvorovima. Razina detaljnosti podataka importiranih spomenutom datotekom iznimno je kvalitetna i s visokim stupnjem detaljnosti. Tako veliku količinu podataka nije moguće obuhvatiti i koristiti u studentskoj licenci PTV-Visuma Fakulteta prometnih znanosti. Stoga je za potrebe izrade diplomskog rada na zamolbu autora tvrtka PTV iz Karlsruhe-a omogućila korištenje pune licence. Osim linkova i čvorova, importirani su i mnogi drugi podaci od kojih su suvišni izbrisani, a ostali iskorišteni za izradu zona i modeliranje javnog prijevoza.

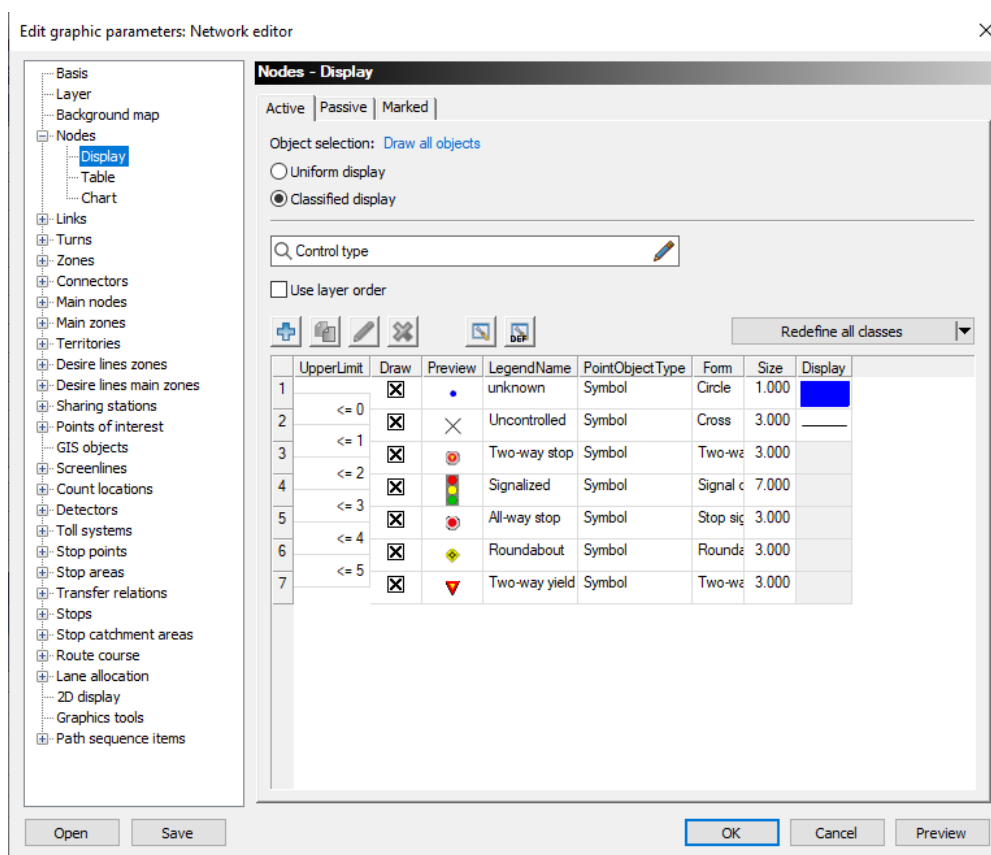
Na Slici 27. prikazan je dio prometne mreže grada Splita kreirane u PTV Visum.



**Slika 27. Prikaz dijela prometne mreže grada Splita u PTV Visum-u**



Nedefinirani nodovi su označeni plavim točkama, signalizirani simbolom semafora, upravljani vertikalnom signalizacijom simbolima iste, a ostali također pripadajućim intuitivnim oznakama. Linkovi su označeni različitim bojama ovisno o vrsti ceste, državne žutom i narančastom, županijske narančastom, lokalne plavom bojom a željeznica isprekidanim crno-bijelim crtama. Stajališta javnog prijevoza su označena njemačkim simbolom za stajalište, velikim slovom “H” u žutom krugu. Svi se elementi mreže mogu modificirati prema želji izrađivača modela. Slika 28. prikazuje dijaloški okvir za odabir simbola nodova ovisno o tipu čvorišta.



**Slika 28. Odabir simbola nodova ovisno o tipu čvorišta**

Na mreži se nalazi 11.364 nodova, uključujući nodove za pješačke tokove. Provjera svakog noda za potrebe diplomskog rada i njihovo ispravljanje bi zahtijevalo iznimno opsežan posao za koji je potrebno znatno vrijeme koje autor nema na raspolaganju zbog ograničenog vremena za izradu diplomskog rada, stoga je provjera i ispravak učinjen ali samo za određene reprezentativne nodove, dok su nužne izmjene navedene nastavno u poglavlju koji se odnosi na smjernice za izradu projekta.

Ukupan broj linkova na mreži je 26.752 također uključujući linkove pješaka. Prikazom liste linkova (Slika 29.) mogu se uređivati podaci o istima. Najvažniji podaci koji se uređuju su: namjena prema vrsti prometa, brzina slobodnog toka, smjer, kapacitet i broj trakova.

List (Links)									
Select list layout...									
Number: 26,752	No	FromNodeNo	ToNodeNo	TypeNo	TSysSet	Length	NumLanes	CapPrT	VOPrT
1	1	1	2	51	BIKE,BUS,CAR,HGV,PED	0.053km	3	1600	70km/h
2	1	2	1	51	BUS	0.053km	3	1600	70km/h
3	2	3	4	21	BUS,CAR,HGV	0.642km	2	3000	100km/h
4	2	4	3	21	...	0.642km	2	3000	100km/h
5	3	5	6	29	BUS,CAR,HGV	0.044km	2	1200	80km/h
6	3	6	5	29	...	0.044km	2	1200	80km/h
7	4	7	8	29	BUS,CAR,HGV	0.070km	2	1200	80km/h
8	4	8	7	29	...	0.070km	2	1200	80km/h
9	5	9	10	29	BUS,CAR,HGV	0.281km	2	1200	80km/h
10	5	10	9	29	...	0.281km	2	1200	80km/h
11	6	11	12	21	BUS,CAR,HGV	0.021km	2	3000	100km/h
12	6	12	11	21	...	0.021km	2	3000	100km/h
13	7	13	14	21	BUS,CAR,HGV	0.520km	2	3000	100km/h
14	7	14	13	21	...	0.520km	2	3000	100km/h
15	8	15	377	70	BIKE,BUS,CAR,HGV,PED	0.160km	1	400	50km/h
16	8	377	15	70	BUS	0.160km	1	400	50km/h
17	9	16	377	70	BUS	0.108km	1	400	50km/h
18	9	377	16	70	BIKE,BUS,CAR,HGV,PED	0.108km	1	400	50km/h
19	10	16	376	60	BIKE,BUS,CAR,HGV,PED	0.181km	1	800	70km/h
20	10	376	16	60	BIKE,BUS,CAR,HGV,PED	0.181km	1	800	70km/h
21	11	17	376	60	BIKE,BUS,CAR,HGV,PED	0.102km	1	800	70km/h
22	11	376	17	60	BIKE,BUS,CAR,HGV,PED	0.102km	1	800	70km/h
23	12	18	10315	60	BIKE,BUS,CAR,HGV,PED	0.029km	1	800	70km/h
24	12	10315	18	60	BIKE,BUS,CAR,HGV,PED	0.029km	1	800	70km/h
25	13	19	10315	60	BIKE,BUS,CAR,HGV,PED	0.054km	1	800	70km/h
26	13	10315	19	60	BIKE,BUS,CAR,HGV,PED	0.054km	1	800	70km/h
27	14	20	21	40	BIKE,BUS,CAR,HGV,PED	0.165km	1	1000	80km/h
28	14	21	20	40	BIKE,BUS,CAR,HGV,PED	0.165km	1	1000	80km/h
29	15	22	23	21	BUS,CAR,HGV	0.153km	2	3000	100km/h
30	15	23	22	21	...	0.153km	2	3000	100km/h

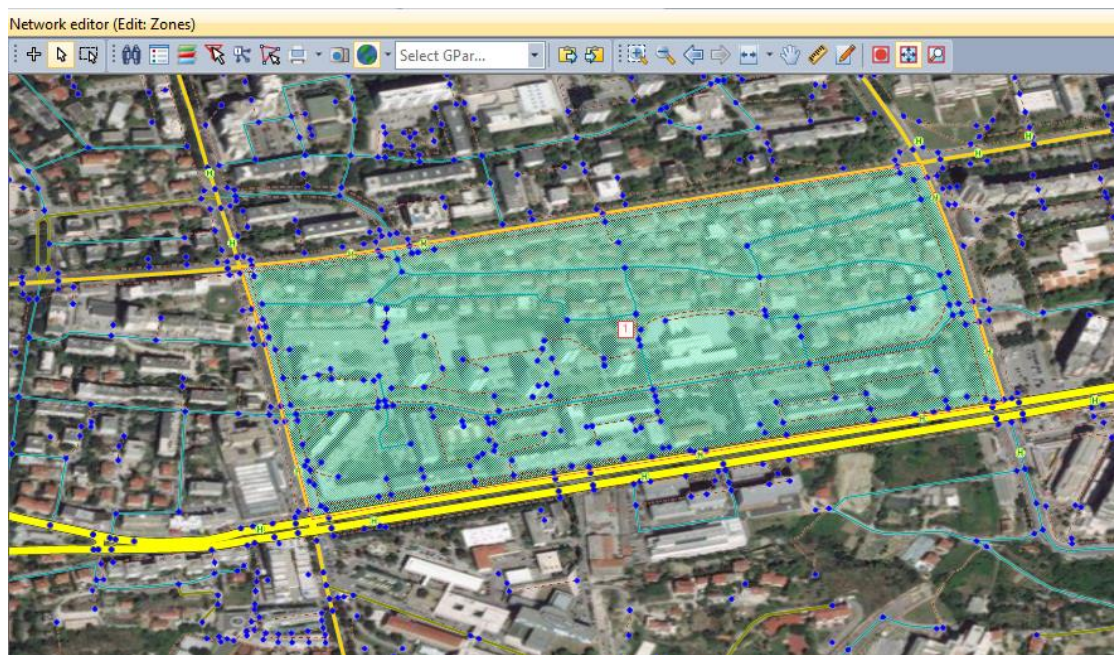
**Slika 29. Lista linkova**

Na Slici 29. vidljiv je prikaz liste linkova sa pripadajućim atributima. Zanimljivo je vidjeti koliko detaljne podatke o elementima mreže sadrže dostupne Open Street Map datoteke. Označavanjem određenog linka može ga se locirati u grafičkom prikazu mreže naziva Network editor. Isto se može činiti i sa svim drugim elementima mreže.

#### 4.2.2. Izrada zona

Prilikom izrade zona granice su određene definiranim granicama gradskih kotareva (Slika 30.), prema kojima je grad administrativno podijeljen, osim posebnih zona koje predstavljaju samo dijelove kotareva, ali su ipak značajan generator putovanja. Vodio se računa i da je svaki dio grada dodijeljen nekoj zoni, nema nedefiniranih dijelova kao što je vidljivo na Slici 31.





**Slika 30. Izrada zone (Zona 1: Blatine-Škrape)**



**Slika 31. Zone grada Splita u programskom alatu PTV Visum**

Za područje interesa izrađeno je 40 zona od kojih su 3 vanjske. Grad Split broji 27 kotareva od kojih su neki podijeljeni na više manjih zona sa ciljem veće detaljnosti modela. Također, važniji atraktori prometa su definirani kao zasebne zone. Svaka zona je spojena sa nekoliko konektora na obližnje nodove. Oni se vežu za čvorove ulaska/izlaska u/z zone, a predstavljaju prosječni trošak (udaljenost, vrijeme) uključivanja nekog putovanja u prometni sustav. Određivanje konektora vršilo se prema osobnoj procjeni s ciljem što preciznijeg prikaza nastajanja putovanja u stvarnom svijetu. Konačni broj konektora je 204 uz napomenu da se pri kreiranju isti odmah udvostručuje zbog suprotnog smjera.

### 4.3. Generiranje putovanja grada Splita

U ovom koraku određeno je koliko putovanja proizvodi i privlači svaka od kreiranih zona.

#### 4.3.1. Ulazni podaci

Za potrebe izrade reprezentativnog modela grada, potrebno je prikupiti veliku količinu primarnih podataka. Ipak, pri izradi ovog diplomskog rada nije se raspolagalo tolikom količinom vremena, novca i ljudstva prijeko potrebnih za takav pothvat. Svi podaci korišteni u modelu su sekundarni, prikupljeni za neku drugu potrebu.

#### 4.3.2. Atributi zone

Svaka zona generira putovanja sukladno formuli koja sadrži određene varijable. Te varijable je potrebno kreirati. Izbor formule te samim time i vrste varijable ponajviše ovisi o dostupnim podacima temeljem kojih se izvodi postupak generiranja putovanja. Za grad Split koriste se formule za produkciju i atrakciju:

$$Production\ function = [broj\ stanova] * 0,41 + [broj\ izlaza] * 1,3 \quad (14)$$

$$Attraction\ function = [broj\ stanova] * 0,10 + [broj\ ulaza] * 1,3 \quad (15)$$

Iz toga proizlaze varijable potrebne za ovaj rad, a to su broj stanova, broj ulaza i broj izlaza. S obzirom da se ne raspolaže sa podacima o broju stanova u odnosu na broj kuća po kotarevima, atribut "broj kuća" je izostavljen iz formule korištene na vježbama.

Broj stanova je varijabla izvučena iz javno dostupnih podataka o stanovništvu. Na službenim stranicama grada nalaze se podaci o kotarevima te o stanovništvu istih (Tablica 2.). Stanovništvo svakog kotara je podijeljeno sa brojem stanovnika po stanu te je na taj način pretpostavljen broj stanova.

Ovakav način nije dovoljno precizan za izradu maksimalno reprezentativnog modela. Znatno detaljniji podaci bi se dobili anketom kako je opisano kasnije u smjernicama za izradu projekta.

**Tablica 2 Stanovništvo po gradskim kotarevima [16]**

<b>Red. br.</b>	<b>NAZIV GRADSKOG KOTARA</b>	<b>Površina (ha)</b>	<b>Broj stanovnika (Popis 2011.)</b>	<b>Gustoća stanovništva (stan./ha)</b>
1	BAČVICE	119	6.762	56,82
2	BLATINE - ŠKRAPE	23	5.682	247,04
3	BOL	52	10.022	192,73
4	BRDA	168	5.884	35,02
5	GRAD	42	5.862	139,57
6	GRIPE	32	5.695	177,97
7	KMAN	33	5.257	159,30
8	KOCUNAR	17	3.916	230,35
9	LOKVE	21	5.955	283,57
10	LOVRET	162	10.517	64,92
11	LUČAC – MANUŠ	36	5.633	156,47
12	MEJE	150	3.898	25,99
13	MEJAŠI	361	6.746	18,69
14	MERRTOJAK	40	7.085	177,13
15	NESLANOVAC	97	3.637	37,49
16	PLOKITE	24	5.942	247,58
17	PUJANKE	40	8.561	214,03
18	RAVNE NJIVE	39	5.049	129,46
19	SIROBUJA	95	2.673	28,14
20	SPINUT	121	7.447	61,55
21	SPLIT – 3	56	9.079	162,13
22	SUĆIDAR	47	10.087	214,62
23	ŠINE	68	1.769	26,01
24	TRSTENIK	67	6.927	103,39
25	VAROŠ	222	4.908	22,11
26	VISOKA	51	5.017	98,37
27	ŽNJAN	166	5.357	32,27
	<b>UKUPNO</b>	<b>1.899</b>	<b>165.367</b>	

Državni zavod za statistiku periodički prikuplja i objavljuje podatke na svojim stranicama. Prema tim podacima u prosječnom hrvatskom kućanstvu živi 2,8 osoba. Za grad Split taj podatak je gotovo jednak te bilježi 2,812 osobe po kućanstvu (Slika 32.).

**2. POPISE OSOBE, KUĆANSTVA I STAMBENE JEDINICE, PRVI REZULTATI POPISA 2011. PO NASELJIMA**  
**ENUMERATED PERSONS, HOUSEHOLDS AND HOUSING UNITS, 2011 CENSUS FIRST RESULTS, BY SETTLEMENTS**

(nastavak)  
 (continued)

	Ukupno popisane osobe Total number of enumerated persons	Ukupan broj stanovnika Total population	Kućanstva Households		Stambene jedinice Housing units	
			ukupno Total	privatna kućanstva Private households	ukupno Total	stanovi za stalno stanovanje Dwellings for permanent habitation
	1	2	3	4	5	6
Solin	24 282	23 985	7 872	7 869	9 252	9 182
Blaca	2	2	1	1	27	27
Kučine	954	946	304	304	347	347
Mravince	1 627	1 611	513	513	652	652
Solin	20 335	20 080	6 564	6 563	7 636	7 572
Vranjic	1 131	1 116	392	390	489	483
Naknadno popisani Enumerated with delay	233	230	98	98	101	101
Split	183 796	178 192	62 906	62 843	76 723	74 573
Donje Sitno	314	314	104	104	179	173
Gornje Sitno	396	391	119	119	208	157
Kamen	1 782	1 691	513	512	696	692
Slatine	1 142	1 106	447	446	1 399	589
Split	171 162	165 893	59 042	58 983	70 729	69 586
Srinjine	1 233	1 218	335	335	440	407
Stobreč	3 013	2 953	902	902	1 178	1 145

**Slika 32. Podaci o broju stanova od Državnog zavoda za statistiku [17]**

Produkcija i atrakcija zona koje nisu stambene u pravilu se određuje brojanjem vozila koja ulaze ili izlaze iz zone. Ranije je već spomenuto da su svi podaci sekundarni pa je tako i za ovaj korak pretpostavljen promet u vršnom satu za zone koje nisu stambene.

Opterećenje vanjskih zona izvedeno je iz PGDP-a brojačkih mjesta (Tablica 3.). Na tim se mjestima vrši kontinuirano brojanje od strane tvrtke Hrvatske ceste d.o.o. Odabrano satno opterećenje iznosi 10% PGDP-a.

**Tablica 3 PGDP lokacija vanjskih zona [18]**

Brojačko mjesto		PGDP	Pretpostavljeno opterećenje vršnog sata
Oznaka	Ime		
5423	Solin	46.941	4.694,1
5422	Stobreč	52.602	5.260,2
5441	Dračevac	40.509	4.050,9

Prema studiji društva koje upravlja autocestama u SAD-u, Federal Highway Administration (FHWA), prosječan broj putnika po vozilu iznosi 1,7. (Average Vehicle Occupancy Factors for Computing Travel Time Reliability Measures and Total Peak Hour Excessive Delay Metrics).

Temeljem tog podatka određen je broj putovanja za zone koje nisu vanjske, a nisu ni stambene. Jedini dostupan podatak o tim zonama je broj zaposlenih uz napomenu da podaci nisu provjereni, već predstavljaju procjenu autora temeljem usmenih razgovora s nadležnim rukovoditeljima navedenih institucija i tvrtki:

- Splitsko brodogradilište zapošljava 2.000 ljudi te se pretpostavlja da generira 1.177 vozila svakog vršnog sata.
- Trgovački centar Mall of Split zapošljava oko 800 ljudi po smjeni te je pretpostavljen broj putovanja u iznosu od 471.
- Trgovački centar City Center one zapošljava oko 700 ljudi po smjeni te je pretpostavljen broj putovanja u iznosu od 412.
- Trgovački centar Joker zapošljava manji broj ljudi, ali područje kreirane zone koriste i razne druge tvrtke i okolno stanovništvo pa je pretpostavljen broj ulaznih putovanja 700 te izlaznih 200.

Za ostale zone broj ulaznih i izlaznih putovanja je također pretpostavljen temeljem osobnog iskustva. Prikaz zona sa pripadajućim vrijednostima atributa prikazan je na Slici 33.



List (Zones)

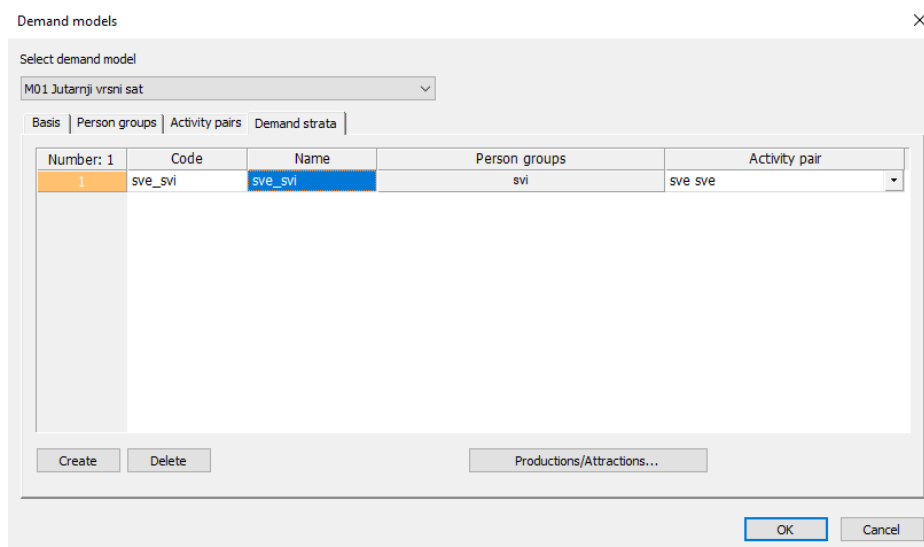
Select list layout...

Number: 40	No	Code	Name	TypeNo	Brojanje_izlaza	Brojanje_ulaza	BS
1	1	Blatine-Skraper	Blatine-Skraper	0	0	0	2021
2	2	Lokve	Lokve	0	0	0	2118
3	3	Gripe	Gripe	0	0	0	2025
4	4	Lucac-Manus	Lucac-Manus	0	0	0	2003
5	5	Plokite	Plokite	0	0	0	2113
6	6	Kampus	Kampus	0	50	500	0
7	7	Split 3	Split 3	0	0	0	3229
8	8	Visoka	Visoka	0	0	0	1784
9	9	Sucidar	Sucidar	0	0	0	3587
10	10	Bol	Bol	0	0	0	3564
11	11	Pujanke	Pujanke	0	0	0	3044
12	12	Kocunar	Kocunar	0	0	0	1393
13	13	Ravne Njive	Ravne Njive	0	0	0	1796
14	14	Neslanovac	Neslanovac	0	0	0	1294
15	15	Kman-stambena zona	Kman-stambena zona	0	0	0	1870
16	16	Kman-poslovna zona	Kman-poslovna zona	0	0	100	10
17	17	Meje	Meje	0	0	0	1386
18	18	Varos-stambena zona	Varos-stambena zona	0	0	0	1746
19	19	Park suma Marjan	Park suma Marjan	0	50	50	50
20	20	KBC Split	KBC Split	0	50	200	0
21	21	Grad-centar	Grad-centar	0	100	300	2085
22	22	Mertojak	Mertojak	0	0	0	2520
23	23	Trstenik	Trstenik	0	0	0	2463
24	24	Trajektna luka, zelj. kol. i autobusni kol.	Trajektna luka, zelj. kol. i autobusni kol.	0	300	500	0
25	25	Bacvice	Bacvice	0	0	0	2405
26	26	Pazdigrad	Pazdigrad	0	0	0	1905
27	27	Mall of Split	Mall of Split	0	30	471	0
28	28	City center One	City center One	0	30	412	0
29	29	Sirobuja	Sirobuja	0	0	0	951
30	30	TC Joker	TC Joker	0	200	700	0

**Slika 33. Prikaz dijela liste zona s pripadajućim vrijednostima atributa**

Najjednostavniji način unošenja podataka o zoni je otvaranje liste zona. Na taj način se ujedno i provjerava da li su za svaku izrađenu zonu uneseni podaci o prethodno definiranim atributima.


Uslijed izostanka detaljnijih ulaznih podataka o slojevima stanovništva i njihovim preferencijama, kreiran je samo jedan stratum potražnje. Taj je stratum jednostavno nazvan “sve\_svi” te je korišten u svim daljnjim podmodelima (Slika 34.). Anketom bi se dobili bolji ulazni podaci o preferencijama slojeva te bi bilo uputno imati više kreiranih stratumata.



**Slika 34. Kreiranje stratuma potražnje**

Nakon kreiranog stratuma i unesenih vrijednosti atributa zone izrađuje se podmodel generiranja putovanja. Prilikom izrade opisane u metodologiji odabire se formula koja odgovara modelu.

Za potrebe rada odabrani ponderi su 0,41 za broj stanova i 1,3 za izbrojena vozila koja izlaze iz zone (Slika 35.). Razlika kod atrakcije je u ponderu za broj stanova koji iznosi 0,1.



**Slika 35. Unos formule za produkciju**

Iako programski alat PTV-Visum jasno prikaže da je radnja uspješno izvršena, otvaranjem dijaloškog okvira definiranih vrijednosti produkcije i atrakcije za željeni stratum provjerena je uspješnost prvog podmodela. Svi redovi su popunjeni što znači da nema zone za koju nije generirana produkcija i atrakcija (Slika 36.).

Define productions/attractions

Code: sve\_svi  
Name: sve\_svi

Number: 40	Zone	Productions	Attractions
1	1	828.61000000	202.10000000
2	2	868.38000000	211.80000000
3	3	830.25000000	202.50000000
4	4	821.23000000	200.30000000
5	5	866.33000000	211.30000000
6	6	65.00000000	650.00000000
7	7	1323.89000000	322.90000000
8	8	731.44000000	178.40000000
9	9	1470.67000000	358.70000000
10	10	1461.24000000	356.40000000
11	11	1248.04000000	304.40000000
12	12	571.13000000	139.30000000

OK Cancel

**Slika 36. Generirana produkcija i atrakcija po zonama**

Iskorištena je i mogućnost uređivanja grafičkih parametara. Odabran je prikaz potražnje u stupcima. Žuti stupci predstavljaju produkciju, a sivi atrakciju putovanja. Povratkom na grafički prikaz jasnije se vidi prometna potražnja po zonama te gdje se nalaze najveći generatori. Očekivano najveći generatori su vanjske zone preko kojih u jutarnjem vršnom satu radnici dolaze na posao iz okolnih gradova i naselja što je grafički prikazano na Slici 37.



**Slika 37. Grafički prikaz generiranja putovanja prema zonama**



## 4.4. Distribucija putovanja grada Splita

### 4.4.1. Izrada SKIM matrice

Prethodno fazi prostorne raspodjele putovanja izrađena je matrica troškova putovanja između zona za prijevoz osobnim vozilima. Ta takozvana PrT SKIM matrica predstavlja troškove putovanja između OD parova (Slika 38.). Za čimbenik troška odabran je  $t_{Cur}$ .

U prometu opterećenoj mreži, vrijeme putovanja na linku određuje se putem takozvane funkcije kašnjenje-opterećenje (poznate i kao funkcija ograničavanja kapaciteta) koja opisuje povezanost trenutnog volumena prometa i kapaciteta.

Rezultat funkcije je vrijeme putovanja u opterećenoj mreži  $t_{Cur}$ .

	1	2	3	4	5	6	7	8	9	10	11	12	13	14
Name	Blatine-Skrape	Lokve	Gripe	Lucac-Manus	Plokit	Kampus	Split 3	Visoka	Sucidar	Bol	Pujanke	Kocunar	Ravne Njive	Neslanovac
Sum	112.73	105.27	117.49	117.52	102.91	115.12	116.31	129.97	102.06	108.86	137.64	114.63	126.81	154.68
1	111.14	0.00	1.06	1.17	1.75	1.52	1.40	0.94	2.47	1.63	3.25	2.53	3.16	4.08
2	103.59	0.99	0.00	1.24	1.79	0.83	1.09	1.28	2.21	1.17	1.66	2.92	2.07	2.70
3	113.46	1.02	1.15	0.00	1.20	1.46	1.97	1.82	2.83	1.80	1.47	3.55	2.65	3.29
4	118.51	1.68	1.77	1.38	0.00	1.88	2.42	2.35	3.26	2.22	1.25	3.82	2.80	3.43
5	101.25	1.46	0.83	1.55	1.76	0.00	1.47	1.67	2.32	1.10	1.16	2.77	1.75	2.38
6	113.86	1.45	1.09	1.96	2.50	1.47	0.00	1.44	1.95	1.47	2.23	2.66	2.20	3.00
7	114.42	0.94	1.28	1.80	2.35	1.67	1.29	0.00	1.96	1.66	2.42	2.78	2.32	3.14
8	128.11	2.51	2.21	2.93	3.47	2.32	1.95	1.96	0.00	1.98	3.03	1.87	2.05	2.87
9	101.08	1.67	1.17	1.89	2.29	1.10	1.47	1.66	1.98	0.00	1.62	2.08	1.30	1.68
10	106.02	1.76	1.47	1.46	1.08	1.19	2.12	2.32	2.96	1.66	0.00	3.10	2.07	2.70
11	135.56	3.29	2.92	3.64	3.73	2.80	2.66	2.78	1.87	2.08	3.06	0.00	1.37	2.19
12	111.87	2.57	2.07	2.75	2.70	1.77	2.20	2.32	2.05	1.31	2.03	1.37	0.00	1.73
13	128.07	3.20	2.70	3.38	3.30	2.40	3.00	3.14	2.87	1.68	2.66	2.19	1.73	0.00
14	152.51	4.02	3.51	4.19	4.12	3.22	3.49	3.61	3.34	2.50	3.48	2.66	2.21	1.90
15	103.63	1.94	1.49	1.90	1.86	0.93	1.79	1.98	2.46	1.09	1.19	2.49	1.46	2.09
16	109.01	2.33	2.04	2.29	1.95	1.52	2.60	2.80	2.91	1.56	1.43	2.94	2.16	1.90
17	222.79	5.62	5.33	5.32	4.50	4.82	5.90	6.09	6.70	5.29	4.45	6.73	5.70	6.00
18	160.74	3.57	3.28	3.27	2.44	3.34	3.93	4.12	4.77	3.74	2.66	5.25	4.23	4.53
19	325.64	8.33	8.04	8.03	7.20	7.52	8.60	8.80	9.40	8.00	7.16	9.43	8.41	8.71
20	150.75	1.76	2.14	1.86	2.43	2.45	2.93	2.42	3.83	2.79	2.78	4.54	3.65	4.28
21	121.54	2.13	2.23	1.76	1.44	2.34	2.93	2.79	3.77	2.73	1.66	4.25	3.23	3.53
22	133.98	2.28	2.33	2.85	3.40	2.71	1.97	1.79	2.10	2.39	3.43	2.91	2.46	3.27
23	123.98	1.64	1.98	2.44	3.01	2.36	1.76	1.58	1.89	2.18	3.12	2.71	2.25	3.07
24	138.39	2.15	2.26	1.79	1.55	2.56	2.97	2.82	3.94	2.90	2.02	4.54	3.51	4.07
25	135.65	1.90	2.01	1.53	1.38	2.31	2.72	2.57	3.69	2.65	1.79	4.31	3.29	3.92
26	169.73	3.48	3.53	4.05	4.60	3.91	3.17	2.99	3.30	3.59	4.64	3.92	3.66	4.14
27	134.39	3.04	2.67	3.39	3.94	2.78	2.41	2.53	1.58	2.44	3.49	1.73	2.32	2.48
28	170.94	4.10	3.73	4.45	5.00	3.84	3.47	3.59	2.64	3.51	4.55	2.79	3.38	3.70
29	161.53	3.66	3.70	4.22	4.77	4.09	3.34	3.16	3.04	3.59	4.57	3.19	3.51	3.21
30	106.62	2.24	1.95	2.04	1.50	1.44	2.52	2.71	3.16	1.81	1.15	3.19	2.32	2.23

Slika 38. PrT SKIM matrica

### 4.4.2. Izrada matrice distribucije putovanja

Izrada podmodela distribucije zahtjeva odabir odgovarajućih parametara. Matricu potražnje je ranije kreirana matrica „sve\_svi“, zatim su definirani kalibracijski parametri. Odabrana je kombinirana formula te ograničenja po produkciji i atrakciji. Prikazom matrice (Slika 39.) moguće je vidjeti prostornu raspodjelu putovanja između OD parova. Lako je iščitati da se uvjerljivo najveći broj putovanja odvija od vanjskih zona prema brodogradilištu i obližnjim zonama.

Matrix editor (Matrix '2 Distribution sve\_svi')

		1	2	3	4	5	6	7	8	9	10	11	12	13	14
	Name	atine-Skraj	Lokve	Gripe	ucac-Manu	Plokte	Kampus	Split 3	Visoka	Sucidar	Bol	Pujanke	Kocunar	lavne Njive	Neslanov
40 x 40	Sum	588.20	610.87	594.99	588.53	608.17	1928.31	932.37	531.25	1013.82	1022.53	899.91	407.11	528.75	385.5
1	Blatine-Skrape	828.61	0.00	10.15	9.92	10.66	10.94	33.07	15.06	10.10	18.81	19.12	17.97	7.92	10.56
2	Lokve	868.38	10.12	0.00	10.66	11.36	10.15	33.23	17.10	10.52	18.62	19.92	18.78	8.11	10.95
3	Gripe	830.25	9.62	10.35	0.00	9.88	10.85	35.44	17.34	10.35	19.22	18.35	18.21	8.00	10.64
4	Lucac-Manus	821.23	10.52	11.14	10.13	0.00	11.24	36.17	17.89	10.39	19.67	17.46	18.08	7.94	10.53
5	Plokte	866.33	11.04	10.21	11.20	11.37	0.00	35.61	18.13	10.65	18.46	18.55	18.72	7.90	10.77
6	Kampus	65.00	0.83	0.81	0.88	0.91	0.87	0.00	1.32	0.77	1.47	1.58	1.39	0.62	0.84
7	Split 3	1323.89	15.01	16.84	17.26	17.91	17.73	51.76	0.00	15.44	30.08	32.03	27.97	12.43	16.80
8	Visoka	731.44	9.83	10.08	10.09	10.22	10.14	30.23	15.03	0.00	16.73	17.85	14.04	6.54	8.92
9	Sucidar	1470.67	19.29	18.76	19.79	20.28	18.48	60.45	30.79	17.59	0.00	33.81	30.29	12.63	17.17
10	Bol	1461.24	19.51	19.73	18.82	17.45	18.80	64.99	32.78	18.84	34.23	0.00	32.35	13.87	18.70
11	Pujanke	1248.04	17.46	17.99	17.71	17.57	17.83	54.42	27.22	14.04	28.79	30.47	0.00	10.31	14.55
12	Kocunar	571.13	7.83	7.90	7.93	7.82	7.66	24.52	12.29	6.65	12.22	13.25	10.48	0.00	6.48
13	Ravne Njive	736.36	10.25	10.48	10.35	10.21	10.26	32.68	16.34	8.91	16.31	17.60	14.54	6.37	0.00
14	Neslanovac	530.54	7.40	7.64	7.45	7.35	7.53	23.42	11.68	6.39	12.31	12.83	10.55	4.68	5.87
15	Kman-stambena zona	766.70	10.26	10.20	10.24	10.09	9.19	32.48	16.45	9.45	16.18	16.37	16.15	6.69	9.25
16	Kman-poslovna zona	4.10	0.06	0.06	0.06	0.05	0.05	0.19	0.09	0.05	0.09	0.09	0.04	0.04	0.05
17	Meje	568.26	7.91	8.27	7.91	7.73	8.20	25.48	12.67	7.01	14.00	13.74	11.95	5.46	7.04
18	Varos-stambena zona	715.86	9.92	10.29	9.83	9.31	10.29	32.28	16.11	9.02	17.71	16.79	15.48	6.97	9.04
19	Park suma Marjan	85.50	1.18	1.24	1.18	1.17	1.24	3.78	1.87	1.03	2.10	2.09	1.75	0.81	1.04
20	KBC Split	65.00	0.81	0.88	0.82	0.85	0.90	2.84	1.37	0.81	1.55	1.54	1.40	0.63	0.82
21	Grad-centar	984.85	13.53	14.30	13.09	12.43	14.38	45.87	22.62	13.01	25.05	22.75	22.49	9.96	13.00
22	Mertojak	1033.20	13.63	14.33	14.16	14.36	14.66	42.68	20.82	11.85	24.38	25.58	21.36	9.51	12.81
23	Trstenik	1009.83	12.65	13.75	13.64	13.94	14.16	41.26	20.06	11.48	23.70	24.93	20.85	9.25	12.54
24	Trajektna luka, zelj. kol. i autobusni kol.	390.00	5.28	5.58	5.11	4.91	5.68	17.89	8.82	5.09	9.84	9.20	8.81	3.92	5.14
25	Bacvice	986.05	12.68	13.43	12.19	11.80	13.74	43.42	21.37	12.43	23.86	22.12	21.55	9.56	12.59
26	Pazdigrad	781.05	10.68	11.21	10.89	10.89	11.32	33.92	16.71	9.36	19.02	19.40	16.31	7.40	9.68
27	Mall of Split	39.00	0.55	0.57	0.56	0.57	0.57	1.72	0.86	0.44	0.95	0.99	0.76	0.37	0.48
28	City center One	39.00	0.56	0.58	0.56	0.56	0.58	1.75	0.87	0.46	0.97	0.99	0.80	0.37	0.49
29	Sirobua	389.91	5.36	5.63	5.46	5.45	5.68	17.05	8.41	4.62	9.50	9.67	7.94	3.68	4.69
30	TC Joker	260.00	3.78	3.87	3.73	3.47	3.63	12.41	6.24	3.53	6.45	5.84	6.02	2.62	3.36

Slika 39. Matrica distribucije putovanja

#### 4.5. Dodjeljivanje putovanja na mrežu grada Splita

Četvrta faza modela izvedena je kreiranjem podmodela PrT assignment. S obzirom da je Split izrazito turistički grad te količina prometa na mreži varira, podmodel je izrađen za zimsko i ljetno razdoblje.

Za referentni objekt odabran je automobil (Car), a za metodu ekvilibrirana, opisana u prethodnom poglavlju. Da bi se operacija mogla izvršiti, u podacima o potražnji odabrana je matrica „sve\_svi“ za segment Car. Izvođenjem podmodela u Network editoru se može vidjeti prometno opterećenje dodijeljeno na mrežu (Slika 40.). Prikazano je crvenom bojom, a širine prikazuju gustoće prometa. Zbog bolje preglednosti, linkovi su prikazani uniformiranim linijama.



**Slika 40. Dodjeljivanje putovanja na mrežu, zimsko razdoblje**

Osim grafičkog prikaza cjelokupne mreže, moguć je pristup i raznim drugim podacima, kao što je promet po elementima mreže. Korisno je vidjeti koja su raskrižja i prometnice najopterećenije te omjer njihovog opterećenja sa kapacitetima istih, kao što je prikazano listom linkova na Slici 41.

List (Links)											
Number: 26,832	No	FromNodeN	ToNodeN	TypeN	TSysSet	Length	NumLane	CapPr	V0PrT	VolVehPrT(A)	VolPersPuT(A)
1	451	408	6590	22	BUS,CAR,HGV	0.069km	3	4500	100km/h	7099	
2	452	6590	11004	22	BUS,CAR,HGV	0.057km	3	4500	100km/h	7099	
3	453	11004	409	22	BUS,CAR,HGV	0.158km	3	4500	100km/h	7099	
4	454	410	408	22	BUS,CAR,HGV	0.124km	3	4500	100km/h	7099	
5	457	409	415	22	BUS,CAR,HGV	0.116km	3	4500	100km/h	7099	
6	823	778	775	22	BUS,CAR,HGV	0.114km	3	4500	100km/h	7099	
7	7219	5608	410	22	BUS,CAR,HGV	0.045km	3	4500	100km/h	7099	
8	11746	415	778	22	BUS,CAR,HGV	0.103km	3	4500	100km/h	7099	
9	12438	9630	10900	22	BUS,CAR,HGV	0.029km	3	4500	100km/h	6103	
10	12439	10900	2367	22	BUS,CAR,HGV	0.010km	3	4500	100km/h	6103	
11	13417	11404	9630	21	BUS,CAR,HGV	0.023km	2	3000	100km/h	6103	
12	7187	32	5879	31	BUS,CAR,HGV	0.035km	3	2600	100km/h	5655	
13	11710	9676	9677	31	BUS,CAR,HGV	0.073km	3	2600	100km/h	5655	
14	11711	9677	3787	31	BUS,CAR,HGV	0.015km	3	2600	100km/h	5655	
15	11712	5879	9676	31	BUS,CAR,HGV	0.101km	3	2600	100km/h	5655	
16	13420	11406	1602	21	BUS,CAR,HGV	0.004km	2	3000	100km/h	5539	
17	11686	9667	5642	22	BUS,CAR,HGV	0.127km	3	4500	100km/h	5499	
18	11687	9668	9667	21	BUS,CAR,HGV	0.177km	2	3000	100km/h	5499	
19	11688	2406	9669	22	BUS,CAR,HGV	0.159km	3	4500	100km/h	5499	
20	12535	10426	9668	21	BUS,CAR,HGV	0.031km	2	3000	100km/h	5499	
21	12536	9669	10426	21	BUS,CAR,HGV	0.170km	2	3000	100km/h	5499	
22	11702	3787	9672	31	BUS,CAR,HGV	0.017km	3	2600	100km/h	5472	
23	11703	9672	10921	31	BUS,CAR,HGV	0.031km	3	2600	100km/h	5472	
24	11704	10921	9673	31	BUS,CAR,HGV	0.415km	3	2600	100km/h	5472	
25	11705	9673	5898	31	BUS,CAR,HGV	0.026km	3	2600	100km/h	5472	
26	165	114	115	21	BUS,CAR,HGV	0.034km	2	3000	100km/h	5266	
27	6981	115	5741	21	BUS,CAR,HGV	0.262km	2	3000	100km/h	5266	
28	11550	5741	435	22	BUS,CAR,HGV	0.174km	3	4500	100km/h	5266	
29	13382	11371	114	21	BUS,CAR,HGV	0.008km	2	3000	100km/h	5266	
30	7437	1602	9880	21	BUS,CAR,HGV	0.054km	2	3000	100km/h	5154	

**Slika 41. Lista najopterećenijih linkova**




Odabirom određenog linka s liste linkova pojednostavljeno je njegovo lociranje u grafičkom prikazu mreže. Prikaz problematičnog linka daje bolji uvid u problem i moguće opcije prilikom osmišljavanja idejnog rješenja. Isti postupak je moguć i s drugim elementima.

Najopterećeniji link predstavlja cestu D8 pred sjeverni ulaz u grad te prikazuje vrijednost od 7.099 putovanja u vršnom satu (Slika 42.).



**Slika 42. Prikaz najopterećenijeg linka**

Za usporedbu opterećenja na nodovima u zimskom i ljetnom razdoblju odabrano je raskrižje ulice Mažuranićevo šetalište i Ulice slobode. Raspodjela prometnih tokova prikazana je na Slici 43.



**Slika 43. Raskrižje Ulice Matice hrvatske i Ulice slobode u zimskom razdoblju**

#### 4.5.1. Dodjeljivanje putovanja za ljetno razdoblje

Za izradu modela ljetnog razdoblja promijenjene su vrijednosti atributa zona prema dostupnim podacima. Umjesto PGDP-a kao izvora podataka za vanjske zone, korišten je PLDP koji prikazuje znatno veće vrijednosti (Tablica 4.)

**Tablica 4 PLDP lokacija vanjskih zona [18]**

Brojačko mjesto		PLDP	Pretpostavljeno opterećenje vršnog sata
Oznaka	Ime		
5423	Solin	56.524	5.652,4
5422	Stobreč	60.032	6.003,2
5441	Dračevac	47.772	4.777,2

Povećan je i broj ulaznih putovanja trajektne luke, centra grada i kotara Varoš uz važnu napomenu da su te vrijednosti temeljene isključivo na osobnoj procjeni.

„Network editor“ jasno prikazuje razliku između zimskog i ljetnog razdoblja već pri samom prikazu cjelokupne mreže (Slika 44.). Vidljivo je značajno povećanje prometnih tokova prema zoni koja obuhvaća trajektnu luku, autobusni i željeznički kolodvor.



**Slika 44. Dodjeljivanje putovanja na mrežu**




Najopterećeniji link ljetnog razdoblja je isti kao i kod zimskog uz značajno povećanje broja putovanja dodijeljenih na isti link. Novi broj putovanja je 8.404 (Slika 45.) što predstavlja povećanje od 15,53%.



**Slika 45. Prikaz najopterećenijeg linka u ljetnom razdoblju**

Na referentnom raskrižju također je zabilježeno povećanje prometa sa 3604 vozila na 4344 što predstavlja povećanje od 17,04%.

Najveći problem u ljetnom razdoblju predstavlja veliki broj lijevih sa istočnog privoza (Slika 46.) koji se povećao u odnosu na model zimskog razdoblja za 40,09%.



**Slika 46. Raskrižje Ulice Matice hrvatske i Ulice slobode u ljetnom razdoblju**

#### 4.5.2. Modeliranje idejnog rješenja

Grad Split je pristupio rješavanju problema ulaza u grad iz smjera sjevera te je u tijeku izgradnja prijelazne rampe između razina državne ceste D8.

Prilikom ulaska u grad Split iz smjera Solina nastaju prometna zagušenja tijekom vršnih sati, ali i ostalih razdoblja u danu za vrijeme turističke sezone. To se događa jer se sav promet na ulazu u grad odvija preko samo dva prometna traka Ulice Zbora narodne garde iako se u nastavku ceste nalazi još jedan ulaz u grad, u smjeru luke te izgrađena gornja razina spomenute ulice (Slika 47.). Nažalost, gornja razina se trenutačno koristi samo kao obilaznica i ne može se preko nje uključiti prema drugom ulazu u grad, Poljičku cestu. Prijedlog rješenja predviđen je kroz izgradnju prijelazne rampe sa svrhom preusmjeravanja dijela prometa kojem je cilj Poljička cesta, na gornju, nedovoljno iskorištenu etažu.

Autor je izradio idejno rješenje koje prikazuje zadovoljavajuće geometrijske elemente [19]. Unatoč prostornim mogućnostima za izgradnju rampe, upitna je opravdanost izgradnje zbog nastanka novih konfliktnih točaka te ograničenog kapaciteta rampe.



**Slika 47. Problem ulaska u grad [19]**


Zona obuhvata se nalazi između dva glavna ulaza u grad Split, tj. na dijelu Ulice Zbora narodne garde. Jedan ulaz u grad predstavlja križanje spomenute ulice sa Ulicom Domovinskog rata, a drugi ulaz križanje te iste ulice sa Poljičkom cestom. Budući da je grad Split izgrađen na poluotoku, sav se promet ulaza i izlaza u/iz grada odvija na navedenim



čvorištima. Ulica zbora narodne garde obuhvaća i gornju etažu koja se trenutačno koristi kao obilaznica te će se ta etaža “spustiti” prijelaznom rampom na donju etažu sa ciljem povezivanja prometa na Poljičku cestu. Na predmetnu Ulicu Zbora narodne garde se spajaju gradske ceste koje za ovaj rad nisu od važnosti, izuzev Ulice Viktora Vida, sa zapadne strane ceste. Naime, predmetni problem i njegovo rješenje obuhvaćaju samo zapadnu stranu ceste.

Ukoliko bi se izgradila prijelazna rampa nastale bi dvije nove točke preplitanja uslijed uključivanja vozila sa lijeve strane kolnika, tj. sa gornje na donju razinu. Razlog tome je promjena dva prometna traka sa ciljem dolaska do desnog dijela kolnika za skretanje prema gradu.


Idejno rješenje izgradnje prijelazne rampe sa ucrtanom signalizacijom prikazan je na Slici 48.



**Slika 48. Idejno rješenje izgradnje prijelazne rampe [19]**


Predloženo idejno rješenje spajanja dviju razina Ulice Zbora narodne garde pretvara gornju razinu, koja je trenutačno nedovoljno iskorištena te se koristi samo kao obilaznica, u cestu koja vodi izravno u centar grada. Iz tog razloga nedvojbeno bi se rasteretila donja razina te bi sjeverni ulaz u grad bio manje zagušen (Slika 49.).





**Slika 49. Model razdvajanja tokova na cesti D8**

Izgradnja rampe bi prema modelu uzrokovala smanjenje opterećenja na sjeverni ulaz u grad u iznosu od 31,19% čime se vjerojatno opravdava ulaganje u izgradnju, ali se velik dio prometa preusmjerava na gornju razinu što uzrokuje nove probleme na mreži (Slika 50.)



**Slika 50. Model razdvajanja tokova na cesti D8 uslijed izgradnje rampe**

Za opravdanost idejnog rješenja bilo bi potrebno izračunati razinu usluge segmenta ceste na kojem će nastati preplitanja korištenjem HCM metodologije. S obzirom na model dobiven korištenjem programskog alata PTV-Visum (Slika 51.), upitna je prihvatljivost predloženog rješenja.



**Slika 51. Model prometnih tokova uslijed izgradnje prijelazne rampe**

## 5. SMJERNICE ZA DOVRŠETAK MODELA


U ovom poglavlju predložene su neophodne radnje za izradu modela koji bi bio relevantna podloga donosiocima odluka. Takav model bi dovoljno reprezentativno prikazivao sva mikro i makro područja koji mogu poslužiti pri izradama projekata zainteresiranim stranama.

### 5.1. Izrada reprezentativne mreže

#### 5.1.1. Korekcije linkova i nodova

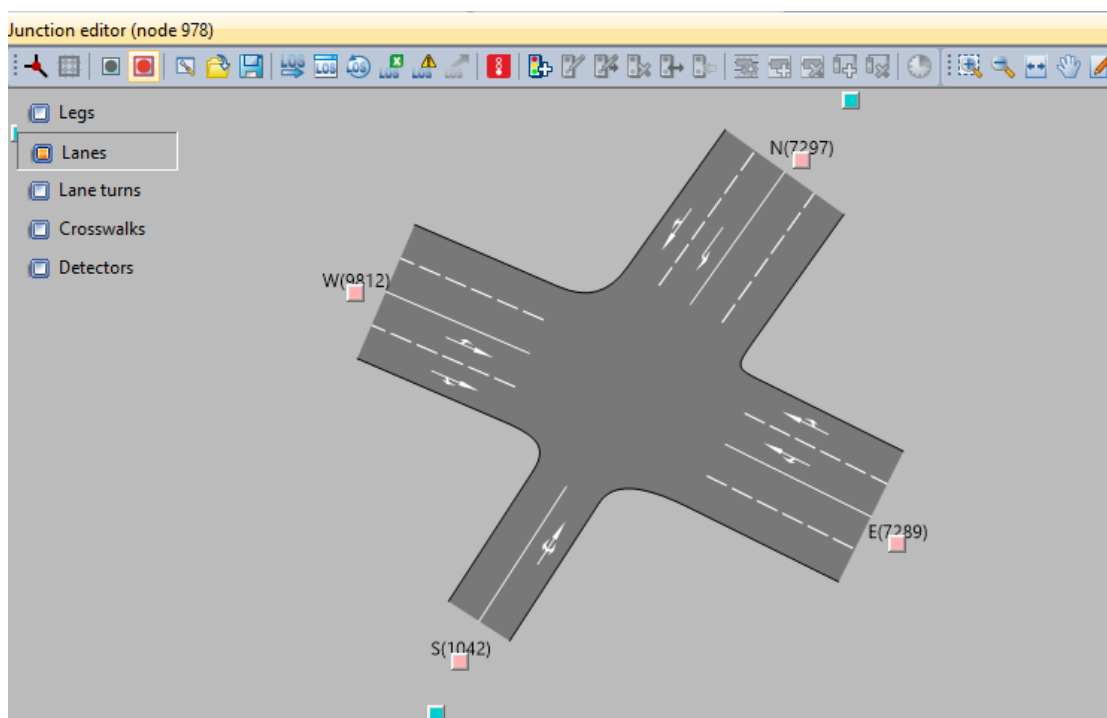
Prilikom izrade modela primijećeni su nedostaci na mreži importirane OSM datoteke. Mreža grada sadrži 11.364 noda i 26.752 linka te ne bi bilo praktično izrađivati mrežu samostalno. Ipak, ako se prione izgradnji reprezentativnog modela, nije prihvatljivo imati greške samo iz razloga što je samo takva datoteka dostupna. Dok je linkovima potrebno samo mijenjati pripadajuće podatke otvaranjem dijaloškog okvira liste linkova, za nodove je potrebno više. Pojedina raskrižja geometrijski ne odgovaraju stvarnom stanju ili su im broj prometnih trakova i smjerovi netočno postavljeni. Model koji bi odgovarao stvarnom stanju može se postići sa nekoliko korekcija.

Za primjer izvođenja korekcije geometrijskih elemenata odabrano je raskrižje Velebitske ulice i ulice Zagorski put prikazano na Slici 52.



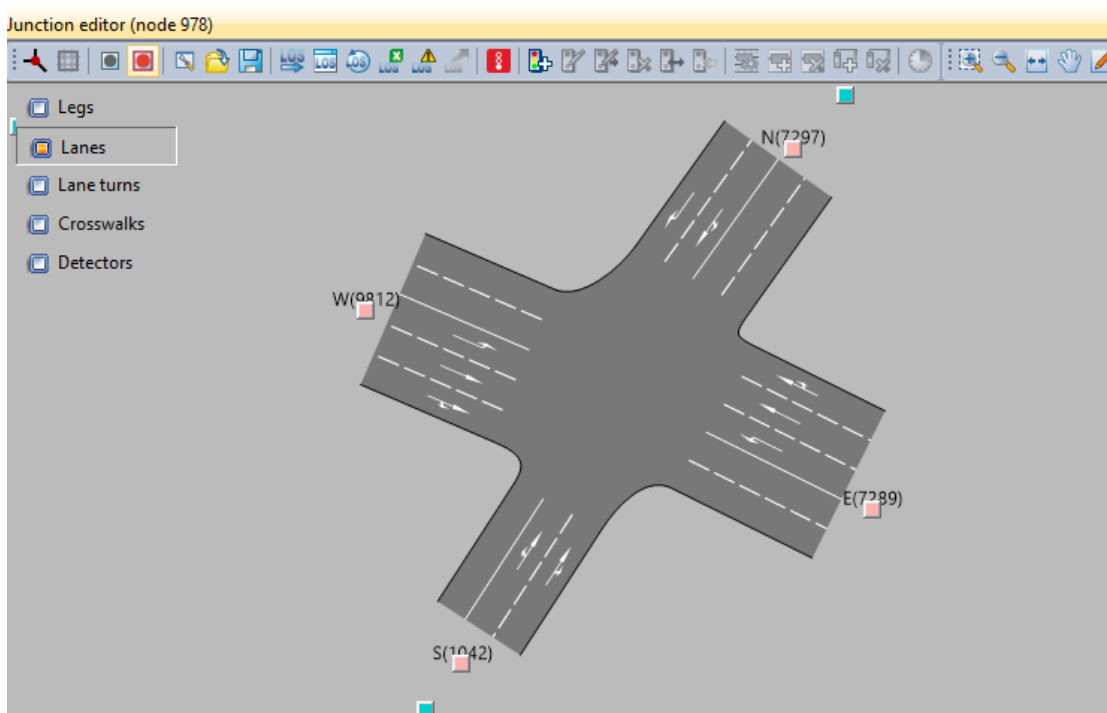
**Slika 52. Ortofoto prikaz stvarnog stanja raskrižja**

Raskrižje importirano u PTV Visum ne odgovara stvarnom stanju. Sjeverni privoz ima netočno postavljena skretanja dok ostalim privozima nedostaje jedan trak (Slika 53.).



**Slika 53. Model raskrižja**

Južnom, istočnom i zapadnom privozu dodani su trakovi koji nedostaju. Također, sjevernom privozu postavljena su ispravna skretanja (Slika 54.).



**Slika 54. Ispravljeni model raskrižja**

U svrhu izrade modela s višim stupnjem detaljnosti potrebno bi bilo unijeti podatke o signalnim planovima signaliziranih raskrižja.

### **5.1.2. Detaljnije zone**

Model izrađen za potrebe ovog rada broji 40 zona. Taj broj zona dovoljan je za planiranje glavnih prometnih tokova u gradu, ali izrada detaljnijeg modela bi omogućila dugogodišnje planiranje zahvata i mjera svih područja na mreži. Predlaže se prikupljanje podataka o prometu u mirovanju, odnosno o svim većim parkiralištima u gradu. Za javna parkirališta podaci su dostupni s obzirom da su u vlasništvu grada, ostala bi se prikupila metodama brojanja i anketiranja.

## **5.2. Modalna raspodjela putovanja**

Treći podmodel četverostupanjskog modela prijevozne potražnje izostavljen je pri izradi ovog rada zbog nedostatka kvalitetnih ulaznih podataka. Prikupljanje i unos podataka o javnom gradskom prijevozu zahtijevaju veće količine vremena i sredstava koji se mogu realizirati ako donosioci odluka prionu izradi visokokvalitetnog modela.

Prije izrade modela modalne prometne potražnje pristupa se izradi ponude javnog gradskog prijevoza. Prvi korak je izrada svih linija javnog gradskog prijevoza. OSM datoteka sadrži već neke linije, ali imaju previše pogrešaka od kojih se najviše ističu netočne rute i izolirana stajališta.

Za provedbu prvog koraka potrebno je prethodno unijeti sve pribavljene podatke o prijevoznicima kao što su detalji o voznom parku i sustavi naplaćivanja. Zatim se pristupa izradi voznog reda za svaku liniju kao na Slici 55.



Timetable (tabular)							
69 vehicle journeys							
Name	BUS 7	BUS 7	BUS 7	BUS 7	BUS 7	BUS 7	BUS 7
LineName	<	<	<	<	<	<	<
DirectionCode	<	<	<	<	<	<	<
Concatenate:VehJourneySections\Valid	Daily	Daily	Daily	Daily	Daily	Daily	Daily
FromTPItemIdentifier	1: 229	1: 229	1: 229	1: 229	1: 229	1: 229	1: 229
Dep	05:00:00	05:15:00	05:30:00	05:45:00	06:00:00	06:15:00	06:30:00
Arr	05:00:00	05:15:00	05:30:00	05:45:00	06:00:00	06:15:00	06:30:00
ToTPItemIdentifier	19: 86	19: 86	19: 86	19: 86	19: 86	19: 86	19: 86
OperatorIdentifier							
Count:VehJourneySections	1	1	1	1	1	1	1
IsCoupled	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
69 vehicle journey sections							
VehCombIdentifier							
ValidDaysIdentifier	1 Daily	1 Daily	1 Daily	1 Daily	1 Daily	1 Daily	1 Daily
FromTPItemIdentifier	1: 229	1: 229	1: 229	1: 229	1: 229	1: 229	1: 229
Dep	05:00:00	05:15:00	05:30:00	05:45:00	06:00:00	06:15:00	06:30:00
Arr	05:00:00	05:15:00	05:30:00	05:45:00	06:00:00	06:15:00	06:30:00
ToTPItemIdentifier	19: 86	19: 86	19: 86	19: 86	19: 86	19: 86	19: 86
Bus Stop Time							
<							
ObjNo	ObjCode	ObjName	Arr / Dep	Arr / Dep	Arr / Dep	Arr / Dep	Arr / Dep
34		Spinut Stadion	^	^	^	^	^
38		Spinut 2	▲ 05:00:00	▲ 05:15:00	▲ 05:30:00	▲ 05:45:00	▲ 06:00:00
36		Split - Poljud	^	^	^	^	^
26		Muzej HAS 4	▲ 05:00:00	▲ 05:15:00	▲ 05:30:00	▲ 05:45:00	▲ 06:00:00
37		Spinut 1	^	^	^	^	^
33		Put Meja	▲ 05:00:00	▲ 05:15:00	▲ 05:30:00	▲ 05:45:00	▲ 06:00:00
184		Banovina	ⓘ 05:00:00	ⓘ 05:15:00	ⓘ 05:30:00	ⓘ 05:45:00	ⓘ 06:00:00

Slika 55. Primjer izrade voznog reda za autobusnu liniju 7

### 5.3. Primarni podaci

Kao što je već prethodno napisano, svi podaci korišteni u modelu su sekundarni. Ipak, izrada reprezentativnog modela zahtjeva prikupljanje primarnih podataka jer su sekundarni rijetko dovoljni.

#### 5.3.1. Određivanje uzorka

Odabir veličine populacije koja bi trebala reprezentativno predstavljati cijeli skup određen je online kalkulatorom veličine uzorka opisanog u trećem poglavlju.

Odabrana je prihvatljivost pogreške od 2%, razina pouzdanosti 95% te distribucija odgovora 50%.

Preporučeni uzorak je 2.308 kućanstava u odnosu na ukupan broj kućanstava grada.

#### 5.3.2. Izrada anketnog obrasca

Anketni obrazac može ispunjavati samo jedan član kućanstva, nije potrebna da svi sudjeluju. Poželjno je prikupiti podatke dohotku, posjedovanju osobnog automobila, veličini kućanstva i njegovoj strukturi, a zatim i podatke o putovanjima. Jako je važna detaljnost putovanja prema

modovima. Bilo bi vrlo korisno ispitati elastičnost potražnje o uslugama javnog gradskog prijevoza. Prema preporuci iz trećeg poglavlja anketiranje je najbolje provesti od sredine rujna do kraja studenoga kada su rute najustaljenije. Također se preporuča unijeti podatke u obrazac o prethodnom radnom dana.

Provjera i dopuna prikupljenih podataka može se izvršiti anketiranjem vozača, brojanjem prometa i kordonskim anketiranjem. Posebno je potrebno naglasiti važnost kordonskog anketiranja za vrijeme ljetnog razdoblja jer se najutjecajnije promjene produkcije i atrakcije događaju na nekoliko karakterističnih lokacija u gradu.

## 6. ZAKLJUČNA RAZMATRANJA

Grad Split drugi je po broju stanovnika te turistički jedan od najznačajnijih gradova u Hrvatskoj. Karakteriziraju ga velike razlike u prometnom opterećenju gradske mreže za vrijeme turističke sezone i ostatku godine. Za vrijeme turističke sezone centar grada i trajektna luka privlače količine putovanja koje premašuju kapacitete cestovne infrastrukture pa dolazi do velikih prometnih zagušenja. U ostatku godine glavni prometni problem predstavlja sjeverni ulaz u grad u jutarnjem vršnom satu jer se sav promet na ulazu u grad odvija preko samo dva prometna traka Ulice Zbora narodne garde koji vode u smjeru industrijskog dijela grada.

U radu je prikazana metodologija izrade četverostupanjskog modela prijevozne potražnje s primjerom grada Splita. Izradom predloženog modela nameće se zaključak da četverostupanjski model prijevozne potražnje relativno reprezentativno prikazuje stvarno stanje. Izrađena je dodjela putovanja na mrežu za zimsko i ljetno razdoblje te prikazana opterećenja odgovaraju ranije navedenim problemima grada.

Također, u želji da se dokaže važnost ovakvog pristupa projektiranju, modelirano je rješenje sjevernog ulaza u grad za koje je u trenutku pisanja ovog rada već započela izgradnja. Smjernicama za dovršetak modela predloženi su neophodni koraci eventualne izgradnje modela koji bi bio relevantna projektna podloga donosiocima strateških odluka o investiranju u prometnu infrastrukturu i prometni sustav grada Splita u cjelini.

Ukoliko grad želi održivo planirati promet na svom području, nužna je izrada prometnih modela uz uporabu simulacijskih alata. Izrada visokokvalitetnog modela u smislu izrade modela s visokim stupnjem detaljnosti mreže i prometa, omogućila bi visoku pouzdanost testiranja idejnih rješenja. Za takav projekt potrebno je koristiti relevantne programske alate te angažirati prometne stručnjake koji imaju potrebna znanja i vještine iz područja prometnog planiranja i modeliranja.

Prijedlog autora je da grad ili zainteresirane strane preuzmu odgovornost za okupljanjem stručnog tima s ciljem izrade projekta reprezentativnog modela grada Splita koji bi sadržavao detaljno izrađenu mrežu s potpuno ispravnim elementima, kako bi se u konačnici dugoročno planirao održivi promet grada Splita.

Također, potrebni su detaljniji i opsežniji ulazni podaci. Vrlo je važno procijeniti potražnju sa što većim stupnjem točnosti kako bi se uštedjeli resursi te prilagodila prijevozna ponuda.



Najbolje je prikupljati podatke periodičkim anketiranjem, a na temelju prikupljenih podataka o preferencijama putnika vršilo bi se ažuriranje modela.

Poznato je da promet u velikoj mjeri generira troškove društva, a zagušena prometna mreža dodatno pogoršava problem. Stoga ulaganje u dugoročno planiranje održive prometne mreže grada, usklađene prema potražnji, nema alternativu.

## LITERATURA

- [1] Barić D. Nastavni materijali iz kolegija Modeliranje i planiranje u cestovnom prometu, 2011. Preuzeto sa: <https://moodle.srce.hr/2018-2019/my>.
- [2] Ortuzar JD, Willumsen L. Modelling Transport, London: John Wiley & Sons, Ltd, 2011.
- [3] Portal tvrtke PTV, Preuzeto sa: <http://www.traffic-inside.com/tag/micro-simulation/>. [Pristupljeno: svibanj 2019.].
- [4] Portal tvrtke Aimsun, Preuzeto sa: <https://www.aimsun.com/the-city-of-montreal/>. [Pristupljeno: svibanj 2019.].
- [5] Portal tvrtke PTV, Preuzeto sa: <http://vision-traffic.ptvgroup.com/en-us/products/ptv-visum/use-cases/>. [Pristupljeno: svibanj 2019.].
- [6] Barić D, Čurepić D, Radačić Ž. Implementation of Relevant Methods in Assessing Traffic-Technological Projects. 2007;19(5):329-36.
- [7] Portal tvrtke PTV, Preuzeto sa: <http://vision-traffic.ptvgroup.com/en-us/products/ptv-vissim/>. [Pristupljeno: lipanj 2019.].
- [8] Kalkulator za računanje uzorka Raosoft, Preuzeto sa: <http://www.raosoft.com/samplesize.html>. [Pristupljeno: lipanj 2019.].
- [9] Portal grada Splita, Preuzeto sa: <http://www.split.hr/Default.aspx?art=1450&sec=756&dm=2>. [Pristupljeno: lipanj 2019.].
- [10] Institut prometa i veza, Studija prostornog i prometnog rješenja željezničkog čvora Split, Zagreb, 2007.
- [11] Prostorno-prometna studija šireg područja Grada Splita, Institut IGH, Split, 2011.
- [12] Portal društva Promet Split d.o.o., Preuzeto sa: <http://www.promet-split.hr/cjenik/tarifne-zone>. [Pristupljeno: srpanj 2019.].
- [13] Portal društva Promet Split d.o.o., Preuzeto sa: <http://www.promet-split.hr/obavijesti/gradski-metro-obavijest-za-putnike>. [Pristupljeno: srpanj 2019.].
- [14] Portal Hrvatske znanstvene bibliografije, Preuzeto sa: [https://bib.irb.hr/datoteka/478635.Mihanovi\\_Stani\\_Baljak.pdf](https://bib.irb.hr/datoteka/478635.Mihanovi_Stani_Baljak.pdf). [Pristupljeno: kolovoz 2019.].
- [15] Portal Zračne luke Split, Preuzeto sa: [http://www.split-airport.hr/index.php?option=com\\_content&view=article&id=160&Itemid=115&lang=hr](http://www.split-airport.hr/index.php?option=com_content&view=article&id=160&Itemid=115&lang=hr).

[Pristupljeno: kolovoz 2019.].

[16] Portal grada Splita, Preuzeto sa: <http://www.split.hr/lgs.axd?t=16&id=11217>.

[Pristupljeno: kolovoz 2019.].

[17] Portal Državnog zavoda za statistiku, Preuzeto sa:

<https://www.dzs.hr/Hrv/censuses/census2011/firstres/censusfirstres.htm>. [Pristupljeno: kolovoz 2019.].

[18] Portal društva Hrvatske ceste d.o.o., Preuzeto sa: <https://hrvatske>

[ceste.hr/uploads/documents/attachment\\_file/file/45/2017.pdf](https://hrvatskeceste.hr/uploads/documents/attachment_file/file/45/2017.pdf). [Pristupljeno: kolovoz 2019.].

[19] Pavić M. Idejno prometno rješenje spajanja Ulice Zbora narodne garde na Poljičku cestu u gradu Splitu, Seminarski rad, Zagreb, 2019.

## Popis slika

Slika 1. "Začarani krug" automobila i javnog prijevoza .....	6
Slika 2. Prekidanje "Začaranog kruga" korištenja osobnih automobila i javnog prijevoza .....	7
Slika 3. Mikroskopski modeli .....	10
Slika 4. Mezoskopski model .....	10
Slika 5. Makroskopski model .....	11
Slika 6. Modeliranje i uzorkovanje .....	15
Slika 7. Shematski prikaz klasičnog četverostupanjskog modela .....	18
Slika 8. Rezultat dodjele putovanja na mrežu u Visum-u .....	20
Slika 9. Prikaz signalnih planova odabranog raskrižja .....	21
Slika 10. Multimodalni model raskrižja u Kopenhagenu .....	23
Slika 11. Područje prikupljanja podataka za OD istraživanja .....	23
Slika 12. Anketni obrazac za projekt Social Car, prva strana .....	26
Slika 13. Anketni obrazac za projekt Social Car, druga strana .....	27
Slika 14. Rasoft, besplatni online kalkulator veličine uzorka .....	30
Slika 15. Cestovna prometna mreža - sustav čvorova i linkova .....	33
Slika 16. Generiranje putovanja .....	34
Slika 17. Umetanje atributa zone .....	37
Slika 18. Generiranje putovanja, procedure sequence (Visum) .....	38
Slika 19. Kreiranje SKIM privatnog prijevoza .....	41
Slika 20. Dijaloški okvir za unos parametara distribucije putovanja .....	42
Slika 21. Modalna razdioba putovanja .....	44
Slika 22. Kreiranje dodjele putovanja privatnog prijevoza .....	45
Slika 23. Unos podataka za izvršenje modalne razdiobe .....	45
Slika 24. Grafički prikaz ekvilibrirane metode .....	48
Slika 25. Kreiranje dodjele privatnog prijevoza .....	49
Slika 26. Izbor matrica prema segmentima potražnje .....	50
Slika 27. Prikaz dijela prometne mreže grada Splita u PTV Visum-u .....	55
Slika 28. Odabir simbola nodova ovisno o tipu čvorišta .....	56
Slika 29. Lista linkova .....	57
Slika 30. Izrada zone (Zona 1: Blatine-Škrabe) .....	58
Slika 31. Zone grada Splita u programskom alatu PTV Visum .....	58
Slika 32. Podaci o broju stanova od Državnog zavoda za statistiku .....	61

Slika 33. Prikaz dijela liste zona s pripadajućim vrijednostima atributa .....	63
Slika 34. Kreiranje stratuma potražnje .....	64
Slika 35. Unos formule za produkciju.....	64
Slika 36. Generirana produkcija i atrakcija po zonama .....	65
Slika 37. Grafički prikaz generiranja putovanja prema zonama .....	65
Slika 38. PRT SKIM matrica .....	66
Slika 39. Matrica distribucije putovanja .....	67
Slika 40. Dodjeljivanje putovanja na mrežu, zimsko razdoblje .....	68
Slika 41. Lista najopterećenijih linkova .....	68
Slika 42. Prikaz najopterećenijeg linka .....	69
Slika 43. Raskrižje Ulice Matice hrvatske i Ulice slobode u zimskom razdoblju .....	69
Slika 44. Dodjeljivanje putovanja na mrežu .....	70
Slika 45. Prikaz najopterećenijeg linka u ljetnom razdoblju.....	71
Slika 46. Raskrižje Ulice Matice hrvatske i Ulice slobode u ljetnom razdoblju.....	71
Slika 47. Problem ulaska u grad.....	72
Slika 48. Idejno rješenje izgradnje prijelazne rampe .....	73
Slika 49. Model razdvajanja tokova na cesti D8 .....	74
Slika 50. Model razdvajanja tokova na cesti D8 uslijed izgradnje rampe .....	74
Slika 51. Model prometnih tokova uslijed izgradnje prijelazne rampe.....	75
Slika 52. Ortofoto prikaz stvarnog stanja raskrižja .....	76
Slika 53. Model raskrižja .....	77
Slika 54. Ispravljeni model raskrižja.....	77
Slika 55. Primjer izrade voznog reda za autobusnu liniju 7 .....	79

## Popis tablica

Tablica 1. Pregled broja zona na primjerima prometnih studija nekih gradova .....	32
Tablica 2. Stanovništvo po gradskim kotarevima .....	60
Tablica 3. PGDP lokacija vanjskih zona .....	61
Tablica 4. PLDP lokacija vanjskih zona .....	70

## Popis priloga

Prilog 1. Model prometne mreže grada Splita u PTV Visum
Prilog 2. Model prometne potražnje grada Splita u PTV Visum





Diplomski rad  
Sveučilište u Zagrebu  
Fakultet prometnih znanosti  
Cestovni promet



Model prometne mreže  
grada Splita  
u PTV Visum

IZRADIO: Matej Pavić  
JMBAG: 0055462793  
MENTOR: izv. prof. dr. sc. Danijela Barić  
KOLEGIJ: 2018./2019.

M 1:20000  
PRILOG 1





		Diplomski rad	Model prometne potražnje grada Splita u PTV Visum	IZRADIO:	Matej Pavić	M	1:20000
		Sveučilište u Zagrebu		JMBAG:	0055462793		
		Fakultet prometnih znanosti		MENTOR:	izv. prof. dr. sc. Danijela Barić	PRILOG 2	
		Cestovni promet		KOLEGIJ:	2018./2019.		





Sveučilište u Zagrebu  
Fakultet prometnih  
znanosti  
10000 Zagreb  
Vukelićeva 4

## IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

Izjavljujem i svojim potpisom potvrđujem kako je ovaj \_\_\_\_\_ diplomski rad  
isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na  
objavljenu literaturu što pokazuju korištene bilješke i bibliografija.

Izjavljujem kako nijedan dio rada nije napisan na nedozvoljen način, niti je prepisan iz  
necitiranog rada, te nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem također, kako nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj  
visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu \_\_\_\_\_ diplomskog rada  
pod naslovom **Primjena četverostupanjskog modela prijevozne potražnje u  
planiranju održivog prometa grada Splita**

na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom  
repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

Student/ica:

U Zagrebu, 13.9.2019 \_\_\_\_\_

\_\_\_\_\_  
(potpis)